

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

ELEKTROTEHNIČKI FAKULTET

Sveučilišni studij

**USPOREDBA REFERENTNOG I PRIKAZANOG
VIDEOSIGNALA PRI TESTIRANJU DTV UREĐAJA
BBT METODOLOGIJOM**

Diplomski rad

Josip Vojak

Osijek, 2017.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 22.09.2017.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu diplomskog rada

Ime i prezime studenta:	Josip Vojak
Studij, smjer:	Diplomski sveučilišni studij Računarstvo
Mat. br. studenta, godina upisa:	D 811 R, 12.10.2015.
OIB studenta:	59576926617
Mentor:	Izv. prof. dr. sc. Marijan Herceg
Sumentor:	
Sumentor iz tvrtke:	Danijel Babić
Predsjednik Povjerenstva:	Doc.dr.sc. Ratko Grbić
Član Povjerenstva:	Doc.dr.sc. Mario Vranješ
Naslov diplomskog rada:	Usporedba referentnog i prikazanog videosignala pri testiranju DTV uređaja BBT metodologijom
Znanstvena grana rada:	Obradba informacija (zn. polje računarstvo)
Zadatak diplomskog rada:	U testiranju DTV (engl. Digital Television) uređaja BBT (engl. Black Box Testing) metodologijom, DTV uređaju koji se testira obično se na ulaz dovodi poznati A/V sadržaj i potom se provjerava odziv uređaja na dani sadržaj. Problem koji treba riješiti u ovom radu je usporedba video sadržaja koji predstavlja odziv uređaja s ulaznim video sadržajem, pri čemu poseban aspekt problema predstavlja vremenska sinkronizacija u ova dva sadržaja. Kada je vremenska sinkronizacija sadržaja postignuta, potrebno je analizirati da li u odzivu uređaja dolazi do nepravilnosti u reprodukciji. (sumentor: Danijel Babić, Institut RT-RK Osijek d.o.o., Cara Hadrijana 10b, Osijek)
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	22.09.2017.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis: Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 29.09.2017.

Ime i prezime studenta:

Josip Vojak

Studij:

Diplomski sveučilišni studij Računarstvo

Mat. br. studenta, godina upisa:

D 811 R, 12.10.2015.

Ephorus podudaranje [%]:

2

Ovom izjavom izjavljujem da je rad pod nazivom: **Usporedba referentnog i prikazanog videosignala pri testiranju DTV uređaja BBT metodologijom**

izrađen pod vodstvom mentora Izv. prof. dr. sc. Marijan Herceg

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ

1	UVOD	1
1.1	Zadatak diplomskog rada.....	1
1.2	Opis zadatka	1
1.3	Sinkronizacija promatranog i referentnog videozapisa	2
1.4	Objektivna ocjena kvalitete videozapisa s referencom.....	3
1.5	QR kod.....	5
2	HIBRIDNO ŠIROKOPOJASNO RAZAŠILJANJE TELEVIZIJSKOG SIGNALA (HBBTV).....	7
2.1	Aplikacijski i potrošački proizvodi.....	7
2.2	Prednosti nad standardnom televizijom.....	8
2.3	HbbTV standard	8
2.4	Televizijski prijemnik (Set-top box).....	8
2.5	Digitalni i HbbTV televizijski prijemnici.....	10
2.5.1	Digitalni televizijski prijemnici.....	10
2.5.2	HbbTV prijemnici	11
2.6	Problematika i primjena testiranja DTV uređaja	12
3	ALGORITMI SINKRONIZACIJE I EVALUACIJE DVAJU VIDEOZAPISA SA I BEZ QR KODA	14
3.1	Sinkronizacija i procjena kvalitete videozapisa uz QR kod	14
3.1.1	Algoritam čitanja QR koda	14
3.1.2	Sinkronizacija videozapisa korištenjem QR kodova.....	17
3.1.3	Procjena kvalitete videozapisa korištenjem QR kodova	21
3.2	Sinkronizacija i procjena kvalitete metodom N PSNR lokalnih maksimuma	25
3.2.1	Sinkronizacija metodom N PSNR lokalnih maksimuma	25
3.2.2	Procjena kvalitete pomoću PSNR vrijednosti i detekcija ispuštanja okvira	29
3.3	Korištene tehnologije, biblioteke, način korištenja	32

4	VREDNOVANJE I DISKUSIJA RADA ALGORITAMA ZA SINKRONIZACIJU I EVALUACIJU VIDEOZAPISA.....	33
4.1	Rezultati i analiza algoritma sinkronizacije i evaluacije uz QR kod	33
4.2	Rezultati i analiza algoritma sinkronizacije i evaluacije korištenjem PSNR-a	35
5	METODE POKUŠAJA I POGREŠKE.....	43
5.1	Tehnike obrade i manipulacije videozapisa i slika	43
5.1.1	Obrada slika za pojednostavljena rješenja	43
5.1.2	Priprema i obrada videozapisa za testiranje	43
5.2	Usporedba histograma korištenjem χ^2 (hi-kvadrat) udaljenosti	46
5.3	Metoda apsolutne razlike osnovnih elemenata slike (eng. <i>pixel comparison</i>)	49
5.4	<i>Freezing</i> algoritam.....	51
6	ZAKLJUČAK	52
7	LITERATURA.....	53
8	SAŽETAK.....	55
9	ABSTRACT.....	56
10	ŽIVOTOPIS	57

1 UVOD

U ovom poglavlju detaljno je opisan zadatak diplomskog rada, osnovni problemi koji su prepoznati u pretpostavci rješenja, znanstveni i istraživački radovi koji su napravljeni iz istog ili sličnih područja, potencijalne probleme, ograničenja i dostignuća.

1.1 Zadatak diplomskog rada

U testiranju DTV (engl. *Digital Television*) uređaja BBT (engl. *Black Box Testing*) metodologijom, DTV uređaju koji se testira obično se na ulaz dovodi video signal kao referentni sadržaj i potom se provjerava odziv uređaja na dani sadržaj. Problem koji treba riješiti u ovom radu je usporedba sadržaja video signala koji predstavlja odziv uređaja s ulaznim video sadržajem, pri čemu poseban aspekt problema predstavlja vremenska sinkronizacija u ova dva sadržaja. Kada je vremenska sinkronizacija sadržaja postignuta, potrebno je analizirati da li u odzivu uređaja dolazi do nepravilnosti u reprodukciji.

1.2 Opis zadatka

Digitalna televizija obuhvaća prijenos zvučnih zapisa (eng. *audio*) i pokretnih slika (eng. *video*) u obliku digitalno obrađenih i multipleksiranih signala. U zemaljskoj televiziji, gdje se signal na većim udaljenostima prenosi radiovalovima, bitna je količina informacija koja se prenosi. Kako ne bi bilo smetnji tokom uobičajenog gledanja televizije, važno je da svi signali u obliku paketa dođu na odredište u određenom vremenskom intervalu i slijedu. Originalni videozapis je većinom prevelik da bi se takav odašiljao mrežom, pa je potrebno izvršiti kodiranje i komprimiranje raznim standardiziranim kompresijskim metodama, kako bi se osigurao učinkovit prijenos i pravovremeni dolazak signala, uzimajući u obzir ograničenje u propusnosti podataka. Osim problema degradacije slike uslijed primjene algoritama kompresije zbog uštede propusnog opsega, kvaliteta slike se smanjuje radi nekih tipičnih nedostataka kao što je problem u primitku signala radi nepovoljnih vremenskih uvjeta, slabe snage odaslanog signala, loše geopozicije prijemnika, itd. Navedeni problemi mogu utjecati na kvalitetu videozapisa i korisničko iskustvo. Na prijemnoj strani, prima se digitalno modulirani signal te obrađuje digitalnim televizijskim prijemnikom. Nakon obrade signala, pomoću DTV prijemnika se prikazuje slika na ekranu korisnika. Da bi se osigurala postojanost nekog videozapisa, potrebno je testirati učinkovitost svih navedenih procesa i ocijeniti kvalitetu videozapisa primljenog putem mreže. Za testiranje, uređaju digitalne televizije koji se testira, dovodi se na ulaz audio i video sadržaj i provjerava se njegova kvaliteta u odnosu na isti referentni videozapis bez gubitaka i kompresije. Slike prenesenog videozapisa se hvataju korištenjem uređaja za hvatanje slika (eng. *frame grabber*), koji mogu

također imati vlastite algoritme kompresije u stvarnom vremenu, kao što su MPEG i JPEG, ili, korištenjem kamere s mogućnošću snimanja s visokim brojem slika u sekundi (eng. *frame per second*). Obzirom da A/V sadržaj doveden na ulaz ne mora vremenski i duljinom trajanja odgovarati referentnom videozapisu, potrebno je prije svega izvršiti vremensku sinkronizaciju ta dva sadržaja. Nakon vremenske sinkronizacije, potrebno je izvršiti usporedbu i analizu je li u odzivu uređaja došlo do određenih nepravilnosti u reprodukciji, primjerice zamrzavanja slike (engl. *freezing*), degradacije kvalitete slike, itd. U idealnom slučaju, referentni i promatrani videozapis su jednake rezolucije i sadrže jednak broj slika po sekundi, no za slučajeve kada se ta dva parametra razlikuju potrebno je odrediti do kojeg stupnja različitosti je moguće naći im točku vremenske sinkronizacije. U cijelom ovom procesu, važno je napomenuti da se provodi takozvano testiranje crne kutije [1] (eng. *Black Box Testing*), u kojoj ne postoji spoznaja o unutrašnjosti digitalnog televizijskog prijemnika, njegovih karakteristika i načina rada, već jedine poznate stvari su ulaz i izlaz iz prijemnika.

Primjena sinkronizacije i evaluacije videozapisa ima visoku primjenu u DTV-u. Tri glavna razloga za provođenje navedenih metoda su:

- osiguranje kvalitete u prijenosu signala
- provjera ispravnosti demodulacije signala na prijemnoj strani u višenamjenskom televizijskom prijemniku
- poboljšanje korisničkog iskustva prilikom gledanja digitalne televizije

1.3 Sinkronizacija promatranog i referentnog videozapisa

Za sinkronizaciju promatranog i referentnog videozapisa uzeta su dva moguća scenarija:

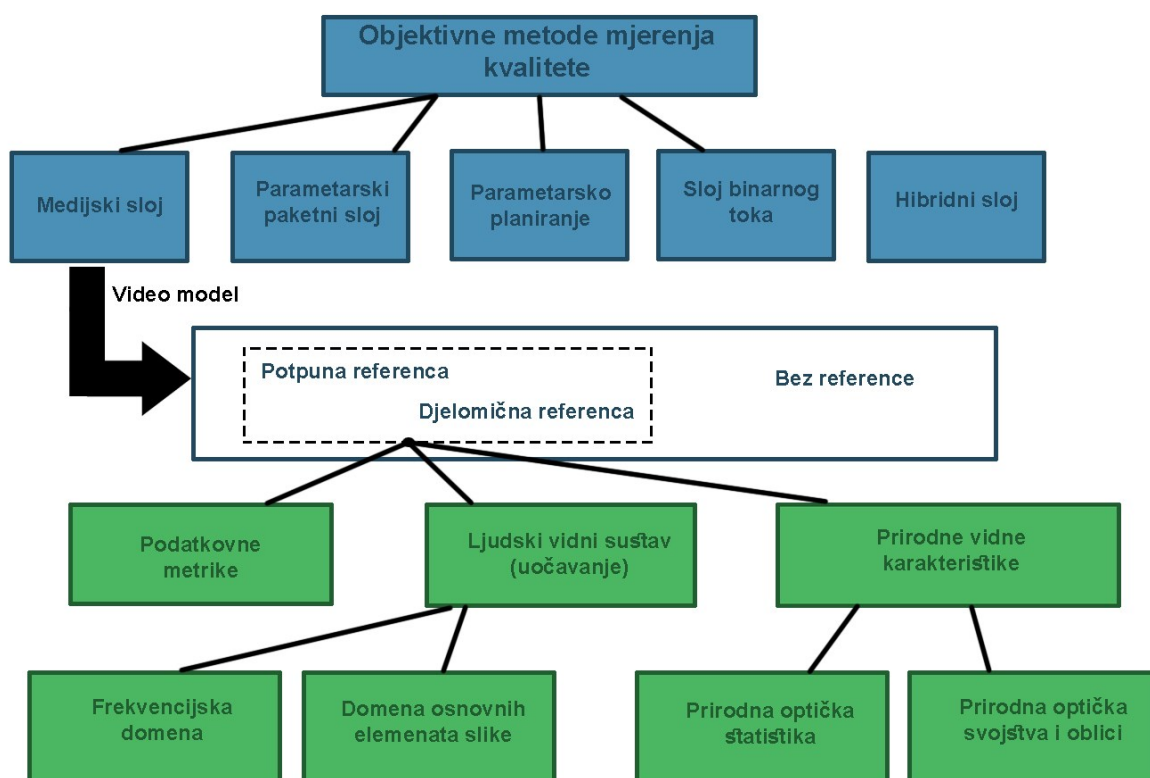
1. scenarij: pokretne slike promatranog videozapisa snimane su pomoću *grabber*-a
2. scenarij: pokretne slike promatranog videozapisa snimane su pomoću kamere s mogućnošću snimanja s velikim brojem slika u sekundi.

Za prvi scenarij, potrebno je pronaći pogodno rješenje koje koristi algoritme objektivne ocjene kvalitete videozapisa s referencom, s kojim će se moći ostvariti sinkronizacija dvaju videa bez obzira na razliku u rezoluciji i s ograničenim stupnjem degradacije.

Za drugi scenarij, uvodi se brzo-odgovarajući kod (eng. *QR code*), koji je postavljen na oba videozapisa i nosi informaciju ili o broju trenutne slike u videozapisu ili o vremenu unutar videozapisa.

1.4 Objektivna ocjena kvalitete videozapisa s referencom

Objektivna ocjena kvalitete videozapisa s referencom je metoda koja koristi jedan ili više algoritama za procjenu kvalitete videozapisa uspoređujući promatrani (komprimirani i kodirani) videozapis s referentnim (netaknutim) videozapisom. Dio je grane digitalne obrade slike, u kojoj se koriste računalni algoritmi za obradu i analizu nad digitalnim slikama. Metode objektivnog mjerenja kvalitete su kvalificirane u pet glavnih kategorija po tipu ulaza, prema [2, str. 22.], koji se koristi u procjeni kvalitete, a prikazani su na slici 1.1. Metode mjerenja kvalitete mogu imati referencu, djelomičnu referencu ili biti bez referentnog videozapisa. Kod metoda s referencom, postoje podatkovne metrike, elementi koje uočava ljudski vidni sustav te prirodne optičke karakteristike.



SI 1.1. Metode objektivnog mjerenja kvalitete

Glavni načini pristupa objektivnoj ocjeni kvalitete videozapisa s referencom su usporedbom osnovnih elemenata slike (eng. *pixel*) ili usporedbom blokova elemenata slike. Usporedba osnovnih elemenata slike se može vršiti na slici u boji (RGB, YUV) te na crno-bijeloj slici (B/W). Osnovne metodologije korištene za usporedbu slika su:

- psihološki i fiziologički modeli vidljivosti
- modeli strukturalne sličnosti
- modeli statistike prirodne scene i teorije informacije
- modeli vizualne pažnje
- pristup strojnim učenjem
- kriterij vjernosti vizualne informacije

Najpoznatiji korišteni algoritmi za procjenu kvalitete videozapisa metodama usporedbe dvaju slika su:


- MSE (Mean Squared Error)
- PSNR (Peak Signal-to-Noise Ratio)
- SSIM (Structural Similarity Indexing Method)
- MS-SSIM (Višestruko-skalirani SSIM)
- VSNR (Vizualni SNR)
- MOVIE (Motion-base Video Integrity Evaluation)

Ostali manje poznati algoritmi: FSIM [3], IWSSIM, VSSIM, VQ model, IFC, NQM, PSNR-HVS-M, VIFP, UQI, XYZ, PSNRY, SNR, WSNR, LINLAB, DCTUNE. Algoritmi koji za sobom povlače strukturalnu sličnost dolaze s pretpostavkom da je ljudski vizualni sustav strogo i visoko prilagođen za ekstrakciju strukturalne informacije iz scene i da stoga mjerenje strukturalne sličnosti pruža dobru aproksimaciju opažene kvalitete slike [4].

Algoritmi su različite složenosti, vremena izvedbe, tipa procjene kvalitete slike (postotak sličnosti, stupanj različitosti), te samim time je i odabir pogodnog algoritma ključan u sinkronizaciji i procjeni kvalitete. Svi od navedenih algoritama testirani su nad više različitih baza podataka koji sadrže videozapise različite kvalitete, duljine, rezolucije, bit rate-a [5] [6] [7]. Provedena je i analiza s različitim tipovima distorzija, koristeći EPFL-PoliMI, HDTV video DB i LIVE Wireless video DB baze podataka, te su dobiveni podaci u kojima, prema dva različita korelacijska parametra – Pearson i Spearman i korijenu srednje kvadratne devijacije [8], u malom stupnju prednjače algoritmi indeksiranja strukturalne sličnosti (SSIM, MS-SSIM). Valja napomenuti kako se ne spominju vremena izvođenja algoritama, što je također bitan faktor. U vremenskom pogledu, u prednosti su jednostavniji algoritmi poput MSE i PSNR. Detaljnijom analizom [9], ukazuje se da odabir jedne ili više metoda usporedbe ovisi prvenstveno o namjeni i namjeri.

Problem koji nastaje je, odrediti pogodan algoritam kako bi se istovremeno ispunila vremenska očekivanja i ostvarila sinkronizacija, te je li dovoljno koristiti jedan algoritam ili više njih kako bi se osigurala točnost.

Potencijalna ograničenja postoje, ukoliko uređaj koji dohvaća slike unosi svoj šum, vrši svoje kodiranje ili mijenja rezoluciju, možda neće biti moguće u potpunosti izvršiti sinkronizaciju i procjenu kvalitete videa.



SI 1.2. Način ručne sinkronizacije dvaju videozapisa u alatu za obradu videa (Vegas Pro)

1.5 QR kod

QR kod je tip matričnog barkoda koji je popularan zbog svoje čitljivosti i mogućnosti pohrane velike količine podataka. Kod se sastoji od crnih modula raspoređenih u kvadratni uzorak na bijeloj pozadini, kao što se vidi na slici 1.3. Količina podataka koja može biti pohranjena u QR kod znak ovisi o tipu podataka, verziji i razini oporavka od greške [10].



SI 1.3. QR kod

Takav kod, lijepi se na svaku sliku videozapisa, kako bi se omogućila sinkronizacija dvaju videa od kojih je promatrani videozapis sniman kamerom, te je stoga loše kvalitete i nije ga moguće sinkronizirati putem nekih od algoritama objektivne ocjene kvalitete.

Kod snimanja videozapisa kamerom, nužan uvjet je da kamera podržava snimanje u barem jednakom broju slika u sekundi kao i referentni videozapis, kako bi se svaki QR kod mogao pročitati. Snimanje duplo većom frekvencijom slika od referentnog omogućuje i veću sigurnost

pri čitanju QR koda, jer kvaliteta kamere i algoritma čitanja QR koda bitno utječu na ukupnu uspješnost čitanja QR koda što utječe i na sinkronizaciju i na procjenu kvalitete.

Ograničenja koja postoje, ovise o kvaliteti odabranog algoritma za čitanje QR koda, kvaliteti kamere i postavkama kamere (osvjetljenje, kut snimanja, boje, specifičnosti kamere).

U narednim poglavljima bit će opisane sljedeće teme:

- Hibridna širokoprijenosna širokopojasna televizija (eng. *Hybrid Broadcast Broadband Television – HbbTV*) – teorijska pozadina digitalne televizije koja objedinjuje prijenos, televiziju putem interneta i širokopojasnu dostavu krajnjem korisniku putem pametnih televizora i digitalnog televizijskog prijemnika. Povezat će se zadatak diplomskog rada s teorijom i primjenom u hibridnoj prijenosnoj širokopojasnoj televiziji te dati na uvid reference koje postoje s takvom problematikom
- Predloženo rješenje problema – deskriptivno, analitičko i algoritamsko
- Rezultati testiranja – prikaz rezultata mjerenja tablično, grafički i deskriptivno
- Metode pokušaja i pogreške – isprobani pristupi problemu koji su pomogli pri rješavanju problema i usmjeravanju ka krajnjem rješenju, ali sami po sebi nisu bili adekvatni za primjenu zbog određenih nedostataka

2 HIBRIDNO ŠIROKOPOJASNO RAZAŠILJANJE TELEVIZIJSKOG SIGNALA (HBBTV)

Hibridno širokopojasno razasijlanje televizijskog signala (eng. *Hybrid Broadcast Broadband Television - HbbTV*) je industrijski standard i promocijska inicijativa za hibridnu digitalnu televiziju koja objedinjuje prijenos, televiziju putem interneta (eng. *Internet Protocol Television – IPTV*) i širokopojasnu dostavu različitih usluga krajnjem korisniku preko televizora i digitalnog televizijskog prijemnika (eng. *set-top box*). Idejno je osmišljen unutar HbbTV konzorcija, koji je spojio tvrtke koje se bave digitalnim emitiranjem i Internetom i uspostavio standard koji pomoću korisničkog sučelja osigurava jednostavno i učinkovito korištenje televizije. HbbTV može prikazati sadržaj digitalne televizije iz niza različitih izvora koje uključuju tradicionalnu televiziju, Internet i priključene uređaje unutar kuće. Za gledanje hibridne digitalne televizije, potrošačima je potreban digitalni prijemnik sa nizom različitih ulaznih konektora, uključujući Ethernet, kao i barem jedan “frekvencijski tuner“ za primanje televizijskog signala. Podešavač frekvencije može biti digitalna zemaljska televizija (DVB-T, DVB-T2), digitalni kabel (DVB-C, DVB-C2) i digitalni satelit (DVB-S, DVB-S2).

2.1 Aplikacijski i potrošački proizvodi

Isporučeni servisi putem HbbTV uključuju :

- poboljšani teletext – često u obliku HTML (eng. *HyperText Markup Language*) stranice, interaktivnost s korisnikom, mogućnost korištenja daljinskog upravljača za teletext.
- nadoknada usluge – video na zahtjev, snimanje videosadržaja, privatna videoteka, povratak na prethodni sadržaj istoga dana.
- elektronički programski vodič – baziran na izborniku koji se konstantno osvježava novim informacijama o emitiranju zvučnog i videozapisa, te pojedinostima o prošlim, sadašnjim i budućim akcijama na pojedinom kanalu.
- interaktivno oglašavanje.
- personalizacija – podešavanje dijelova ili kompletnog grafičkog korisničkog sučelja prema vlastitim potrebama i afinitetima.
- glasanje.
- igre/dodatni oblici zabave.
- povezanost sa društvenim mrežama – mogućnost objave gledanog sadržaja, pregled recenzija o filmu/seriji sa stranica društvenih mreža.
- druge multimedijske aplikacije.

2.2 Prednosti nad standardnom televizijom

HbbTV uređaji omogućuju potrošačima uvid u sve gore navedene servise putem televizijskog ekrana s jednim uređajem. Osim šireg opsega sadržaja od opskrbljivača televizijske usluge, od tradicionalne televizije, videozapisa na zahtjev, servisa za gledanje sadržaja koji je već prošao, potrošači imaju pristup korisnički generiranom sadržaju koji može biti pohranjen na vanjskom čvrstom disku ili na skladištu u oblaku računala.

2.3 HbbTV standard

Osim što pomaže potrošačima, uvođenje HbbTV standarda također je od koristi i proizvođačima opreme i davateljima TV usluga koji u ovom trenutku proizvode sklopovlje i sadržaj specifičan za svaku državu kako bi zadovoljili standard te države.

HbbTV specifikacija je razvijena od strane industrijskih članova konzorcija i temeljena je na elementima postojećih standarda i mrežnih tehnologija koje uključuju Open IPTV Forum, CEA, DVB i W3C. Standardna specifikacija je poslana do kraja studenog 2009., a objavljena pod referencom ETSI TS 102 796 u lipnju 2010.

Aplikacije za HbbTV su temeljene na HTML-u [10,], i iskorištavaju HTML5 i CE-HTML opisne jezike, ali iskorištavaju samo podskup mrežnih standarda, a razvojni inženjeri moraju koristiti specijalizirane alate za validaciju.

Tab. 2.1. Popis objavljenih HbbTV standarda

<i>HbbTV verzija</i>	<i>ETSI verzija</i>
<i>HbbTV 1.0</i>	TS 102 796 v1.1.1 – lipanj 2006.
<i>HbbTV 1.5</i>	TS 102 796 v1.2.1 – studeni 2012.
<i>HbbTV 2.0</i>	TS 102 796 v1.3.1 – studeni 2015.

Očekuje se da će iduća inkrementalna verzija HbbTV standarda uključivati funkcionalnosti od MHEG-5 interaktivne platforme srednjeg sloja koja se koristi za digitalnu zemaljsku televiziju u Velikoj Britaniji, kako bi se olakšala tranzicija iz MHEG-5 u HbbTV.

2.4 Televizijski prijemnik (Set-top box)

Televizijski prijemnik je informacijski uređaj koji sadrži televizijski „frekvencijski tuner“ za ulaz i prikazuje izlaz, pretvarajući izvor signala u sadržaj u obliku koji je moguć za prikaz na

televizijskom ekranu ili drugim oblicima uređaja za prikaz. Koriste se u kablovskoj televiziji, satelitskoj televiziji i televiziji „putem zraka“.

Izvori televizijskog signala mogu biti sljedeći:

- Ethernet kabel
- satelitska antena
- koaksijalni kabel
- telefonska linija (uključujući DSL vezu)
- antena visoke frekvencije (VHF)
- antena ultra visoke frekvencije (UHF)

Sadržaj koji se može nositi signalima može biti vezan za videozapis, zvučni zapis, Internet mrežne stranice, interaktivne videoigre itd.

Neka od najpoznatijih svojstava televizijskog prijemnika se dijele na programska svojstva i pogodnosti.

Važna programska svojstva su:

- elektronički programski vodič – interaktivni vodič koji pruža korisnicima televizije, radija i drugih medijskih aplikacija kontinuirani ažurirani izbornik koji prikazuje servise i informacije o rasporedu trenutnih i nadolazećih programa. Neki vodiči omogućuju i pregled prošlih programa kako bi se promovirala opcija gledanja programa koji su već prošli.
- favoriti – svojstvo koje omogućuje korisnicima odabir željenih kanala, kako bi im u budućnosti mogli lakše i efikasnije pristupiti.
- brojač (eng. *timer*) – omogućuje korisnicima da programiraju i osposobe prijemnik da automatski prebaci između kanala u određenom trenutku što je korisno ukoliko korisnik želi snimati nekoliko kanala istovremeno dok nije u prisutnosti.
- snimanje *Scart* konektorom – korisnik odabire TV programe na elektroničkom programskom vodiču u određeno vrijeme, a prijemnik šalje kontrolni signal putem *Scart* konektora koji ukaže kompatibilnom VCR ili DVR uređaju na početak ili kraj snimanja.

Važne pogodnosti za navesti su:

- kontrole na prijemniku – neki modeli imaju kontrole na prijemniku kao i na daljinskom upravljaču, što je korisno ukoliko korisnik izgubi daljinski upravljač ili se baterije isprazne.

- univerzalni daljinski upravljač – omogućuje korištenje istog daljinskog upravljača za osnovne funkcionalnosti i na ostalim uređajima (poput uključivanja i isključivanja televizora, prilagodbe jačine zvuka, promjena između digitalnih i analognih TV kanala te promjena među zemaljskih i internet kanala)
- roditeljsko zaključavanje – ili takozvani filtri sadržaja, omogućuju korisnicima/vlasnicima da omoguće/onemoguće pristup pojedinim kanalima koji nisu pogodni za sve uzraste koristeći osobni identifikacijski broj.
- alternativne aplikacije – neke aplikacije su razvile svoja svojstva koja su slična onima na televizijskim prijemnicima signala radi povećanja kompleksnosti i programskih grešaka na istim
- ažuriranja mikroprograma koji upravlja radom uređaja

2.5 Digitalni i HbbTV televizijski prijemnici


U ovom potpoglavlju bit će objašnjena teorija digitalnih televizijskih prijemnika, arhitektura i primjena istih, te razlika između tipičnih digitalnih televizijskih prijemnika i HbbTV prijemnika.

2.5.1 Digitalni televizijski prijemnici

Digitalni televizijski prijemnik je napravljen s ciljem prijelaza s analognog na digitalni prijenos televizijskog signala. Kako bi se TV sadržaj pripremio i poslao korisniku digitalnim putem, mora proći kroz sekvencu operacija: video kodiranje, audio kodiranje, priprema tokova s metapodacima [11] (prijevodi, teletekst), paketizacija u elementarne tokove, multipleksiranje, paketizacija u prijenosni tok, zaštita sadržaja, zaštitno kodiranje, digitalna modulacija i slanje odgovarajućim prijenosnim putem. Na prijemu, kod korisnika, prije reprodukcije, moraju se dogoditi sljedeće operacije: prijem, tj. izdvajanje noseće frekvencije, demodulacija, rekonstrukcija prijenosnog toka, čitanje zaštićenog sadržaja, demultipleksiranje, tj., izdvajanje elementarnih tokova, video dekodiranje, audio dekodiranje, dekodiranje tokova s metapodacima, sinkronizacija i reprodukcija na ekran i zvučnike.

Osobina digitalnog televizijskog prijemnika je njihova visoka integriranost i gotovo sve funkcije su realizirane u okviru jednog integriranog kola zvanog „sistem na čipu“. Uređaje za prijem digitalnog televizijskog signala također odlikuje i niska cijena komponenti. Jednako važan aspekt koji čini arhitekturu digitalnog televizijskog prijemnika kompleksnijom je činjenica da uređaj relativno niske cijene ima zadatak prenijeti sadržaj nekoliko redove veće vrijednosti.

Srž uređaja za prijem digitalnog televizijskog signala je dohvaćanje signala, njegova demodulacija, demultipleksiranje, dekodiranje i reprodukcija na odgovarajućim izlaznim podsustavima. Digitalni televizijski prijemnik predstavlja računalni sustav u kojemu su sve funkcionalnosti kojima se manipulira signalom u bilo kojem obliku, koje su izdvojene u posebne sklopovske blokove radi sklopovskog ubrzanja.



SI 2.1. Sklopovska arhitektura uređaja za prijem digitalnog televizijskog signala

Osim blokova za manipuliranje signalom, na uređaju je i centralni procesor koji upravlja cjelokupnim uređajem i odlučuje u procesu obrade signala; dodatno, diskretne komponente uključuju radnu memoriju, brzu memoriju (eng. *flash*), napajanje i brojne ulazno/izlazne komponente.

2.5.2 HbbTV prijemnici

HbbTV prijemnik za obradu digitalnog televizijskog signala se počeo koristiti od 2010. godine s novom generacijom i uz DVB-T2 standard. DVB-T2 “frekvencijski tuneri” omogućuju prijem zračnih zemaljskih programa visoke razlučivosti. Faza servisa visoke razlučivosti digitalne televizije je ohrabрила proizvođače da porinu u proizvodnju novih hibridnih prijemnika [13], koji osim tradicionalnih svojstava i isporuke IP servisa, imaju integrirano mjesto za pametnu karticu koja omogućuje potrošačima da primaju kriptirane premijske televizijske servise koje uključuju

sport i filmove. Takvi prijemnici omogućuju agregaciju upravljanih (kablovskih) i neupravljanih (mrežnih) tradicionalnih linearnih TV prijenosa. Također, ukoliko je više uređaja prisutno na mreži, prijemnik omogućuje korisniku izbor gdje će slati medijski sadržaj.

Hibridna platforma omogućuje operaterima da povećaju svoj prosječni prihod po korisniku, a ujedno i eliminiraju dupliciranje u troškovima i investiranju u instalacije mrežne infrastrukture.

2.6 Problematika i primjena testiranja DTV uređaja

Glavna primjena digitalnog televizijskog prijemnika je da prima digitalno modulirani signal, obrađuje ga već spomenutim metodama, i pruža krajnjem korisniku uslugu gledanja televizije na zaslonu televizora ili nekom drugom uređaju koji to omogućuje. Zbog brojnih problema koji mogu nastati prilikom kodiranja, komprimiranja, prijenosa transportnog toka, te reverznih operacija, kao i zbog sve veće kompleksnosti novijih uređaja te mogućih grešaka u programiranju, može doći do lošeg iskustva prilikom korištenja uređaja ili gledanja televizije iskustvo koje korisnik primi može biti uvelike oštećeno. Rezultat toga je nezadovoljstvo korisnika, žalbe i promjena televizijskog operatera, što direktno utječe na prihod opskrbljivača televizijskog signala. Kako bi se takve stvari izbjegle, ili barem svele na minimum, jedan od bitnih čimbenika u proizvodnom procesu je kontrola i osiguranje kvalitete vlastitog proizvoda.

Obzirom da je sklopovlje podložno kvarovima, a aplikacijsko programsko sučelje pisano od strane ljudi, treba imati na umu ljudsku pogrešku, kao i ograničenost pojedinih algoritama. Zbog toga, vrlo je važno konstantno provjeravati kvalitetu usluge koje se pruža, testiranjem uređaja, kao i cjelokupnog procesa pružanja usluge od izvora do potrošača. Još jedna bitna stavka je osiguranje da aplikacije rade na širokom spektru različitih HbbTV uređaja [14], što predstavlja poseban izazov. Čak i ukoliko je uređaj certificiran od strane testnog odjela, ne postoji jamstvo da će raditi u svakom trenutku s HTML i JavaScript svojstvima koja nisu uključena u HbbTV specifikacije. Razvojni inženjeri aplikacije trenutno imaju nekoliko opcija da poboljšaju načine testiranja:

- statički aplikacijski testni alati
- testiranje na pretraživačima koji su temeljeni na računalima koristeći emulatore
- testiranje na različitim prijemnicima koristeći kolektor prijemnika

Glavni aspekt u ovom radu na koji se obraća pažnja je digitalni televizijski prijemnik, koji se testira metodom crne kutije, odnosno, bez spoznaje o unutrašnjosti (sklopovskoj i aplikacijskoj). Izlazni signal s prijemnika, osim prikaza na ekran, može se snimiti na dva načina: uređajem za hvatanje slika videozapisa i videokamerom. Nakon snimanja izlaznog signala s DTV uređaja, takav

videozapis se uspoređuje s originalnim videozapisom. Prvotni problem koji nastaje je pronaći sinkronizacijsku točku između promatranog i referentnog videozapisa, obzirom da se konstantno pušta signal jednog transportnog toka u beskonačnoj petlji, te tijekom dohvaćanja isječka videozapisa s prijemnika, ne zna se o kojem vremenskom trenutku u videozapisu je riječ u odnosu na referentni, te je potrebno pronaći adekvatan algoritam za vremensko usklađivanje. Ukoliko je promatrani videozapis dobiven dohvaćanjem slika putem takozvanog, *frame grabber*-a, vremensku usklađenost je nužno ostvariti algoritmima usporedbe slike. U suprotnom, ako je promatrani videozapis dobiven snimanjem videokamerom visoke kvalitete, vremenska sinkronizacija se ostvaruje čitanjem i usporedbom QR koda. Nakon pronalaska točke sinkronizacije, ocjenjuje se kvaliteta videozapisa, na način da se uspoređuje slika s promatranog videozapisa sa slikom s referentnog videozapisa. Problemi koji se pretražuju su vezani uz ispuštanje pojedinih slika u videozapisu (eng. *freezing*), degradacije slike (primjerice *blocking*, promjena boje, rezolucije i slično). Koncept je zamišljen tako da, digitalni prijemnik konstantno prikazuje videozapis, svakih nekoliko sekundi/minuta dohvaća isječak/dio videozapisa i uspoređuje sa referentnim videozapisom. Cilj je primijetiti nedosljednosti unutar promatranog videozapisa ukoliko postoje, kako bi se pravovremeno moglo reagirati i osigurati adekvatnu programsku podršku.

3 ALGORITMI SINKRONIZACIJE I EVALUACIJE DVAJU VIDEOZAPISA SA I BEZ QR KODA

U ovom poglavlju su opisana rješenja, dani rezultati i način testiranja sinkronizacije i procjene kvalitete referentnog i promatranog videozapisa, sa sljedećim uvjetima:

1. Videozapis dohvaćen putem *grabber* uređaja, slike videozapisa sadrže QR kod
2. Videozapis dohvaćen putem *grabber* uređaja, slike videozapisa ne sadrže QR kod
3. Videozapis sniman kamerom, slike videozapisa sadrže QR kod

3.1 Sinkronizacija i procjena kvalitete videozapisa uz QR kod

Sljedeće rješenje se odnosi na videozapise koji sadrže QR kod na svojim okvirima, a snimani su kamerom ili su dohvaćeni putem *grabber* uređaja. Prikazani su rezultati dva algoritama otvorenog koda za čitanje QR koda sa slike te opis rada samog algoritma za sinkronizaciju i detekciju ispuštenih slika rekonstruiranog videozapisa.

3.1.1 Algoritam čitanja QR koda

Za čitanje QR koda, izabrana su i testirana dva softverska rješenja otvorenog koda (eng. *open source*):

- quirc (C biblioteka)[15]
- zxing (C++ biblioteka)[16] – ne čita bitmap datoteke

Za potrebe testiranja, kreirani su sljedeći testni slučajevi, sa slikama i videozapisima:

1. Čisti, generički QR kodovi (idealni slučaj).
2. Nasumični isječci QR koda, slikani kamerom/mobilnim telefonom različite kvalitete.
3. Slike uslikane kamerom (Iphone SE), uz proizvoljan kut snimanja i osvjetljenje.
4. Videozapis snimljen kamerom (Iphone SE), fokusiran na QR kod, te podjela slika videozapisa na slike vidljive/čitljive ljudskom oku i nečitljive.
5. Videozapis snimljen kamerom (Iphone SE), fokusiran na monitor (podjela slika videozapisa na čitljive i nečitljive slike ljudskom oku).
6. Videozapis snimljen kamerom (Iphone SE), fokusiran na monitor, slike videozapisa reskalirane na 0.3x ukupne rezolucije (podjela slika videozapisa na čitljive i nečitljive slike ljudskom oku).

7. Videozapis snimljen kamerom (Iphone SE), fokusiran na monitor, odrezana regija veličine ~4x veća od veličine QR koda (podjela slika videozapisa na čitljive i nečitljive slike ljudskom oku).
8. Slike koje ne sadrže QR kod, radi provjere lažne detekcije (eng. *false positive*).

Slijede rezultati testiranja oba QR dekodera, sa sljedećim parametrima:

- Algoritam – naziv algoritma
- Rezolucija – rezolucija testnih slika (razno – od 480x280 do UHD rezolucije)
- N – broj testnih slika
- N_u – broj uspješno pročitanih QR kodova sa testnih slika
- % – postotak uspješno pročitanih QR kodova sa testnih slika
- ms – brzina izvođenja algoritma za set od N slika

Tab 3.1. Prikaz rezultata za testni slučaj 1.

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	125x125	60	60	100	135
<i>zxing</i>	125x125	60	60	100	153

Tab 3.2. Prikaz rezultata za testni slučaj 2.

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	razno	26	12	48	178
<i>zxing</i>	razno	26	16	61	396

Tab 3.3. Prikaz rezultata za testni slučaj 3.

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	4032x3024	26	4	15,3	4086
<i>zxing</i>	4032x3024	26	9	34,6	38373

Tab 3.4. Prikaz rezultata za testni slučaj 4. (čitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	1920x1080	154	148	96,1	4675

<i>zxing</i>	1920x1080	154	152	98,7	23147
--------------	-----------	-----	-----	------	-------

Tab 3.5. Prikaz rezultata za testni slučaj 4. (nečitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	1920x1080	107	0	0	3310
<i>zxing</i>	1920x1080	107	6	5,6	39966

Tab 3.6. Prikaz rezultata za testni slučaj 5. (čitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	1920x1080	137	103	78,4	4130
<i>zxing</i>	1920x1080	137	134	97,8	20020

Tab 3.7. Prikaz rezultata za testni slučaj 5. (nečitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	1920x1080	87	0	0	2609
<i>zxing</i>	1920x1080	87	15	17,2	28562

Tab 3.8. Prikaz rezultata za testni slučaj 6. (čitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	480x270	137	10	7,3	386
<i>zxing</i>	480x270	137	6	4,4	36000

Tab 3.9. Prikaz rezultata za testni slučaj 6. (nečitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	480x270	87	0	0	383
<i>zxing</i>	480x270	87	1	1,1	2486

Tab 3.10. Prikaz rezultata za testni slučaj 7. (čitljive slike)

Algoritam	Rezolucija	N	N_u	%	ms
<i>quirc</i>	550x450	137	105	76,6	621
<i>zxing</i>	550x450	137	136	99,3	3046

Tab 3.11. Prikaz rezultata za testni slučaj 7. (nečitljive slike)

Algoritam	Rezolucija	N	N _u	%	ms
<i>quirc</i>	550x450	87	0	0	505
<i>zxing</i>	550x450	87	14	16,1	4043

Tab 3.12. Prikaz rezultata za testni slučaj 4. (nečitljive slike)

Algoritam	Rezolucija	N	N _u	%	ms
<i>quirc</i>	razno	134	0	0	31759
<i>zxing</i>	razno	134	0	0	263097

Vidljivo je u tablici 3.10. da za čitljive slike jednake rezolucije, *zxing* ima drastično veći postotak uspješnosti čitanja koda. Također, za svaki slučaj izuzev šestog testnog slučaja, *zxing* daje puno bolje rezultate čitanja.

Uočava se da je QR dekodirer *quirc* može raditi u stvarnom vremenu, izuzev toga, licenciran besplatnom BSD licencom, te je puno brži za veće slike i osjetno brži za manje slike od drugog algoritma. *Zxing* algoritam koristi OpenCV, biblioteku za računalni vid, te je licenciran Apache2.0 licencom i ne čita bitmap datoteke. Brzina obrade slika kod *zxing* biblioteke je sporija od *quirc* biblioteke, no znatno je učinkovitija, te je njen algoritam može pročitati veći broj QR kodova sa testnih slika, pri čemu i neke od oku nečitljivih kodova. Obzirom da rad u stvarnom vremenu nije jedno od ograničenja, odabran je *zxing* zbog učinkovitosti čitanja.

Obzirom da odabrano rješenje ne čita bitmap datoteke, potrebno je u algoritam implementirati rad s bitmap-om jer će se sva potencijalna obrada slika (reskaliranje, pretvorba iz RGB u crno-bijelu sliku, računanje prosjeka R, G i B komponenti, itd) vršiti unutar programa, u bitmap obliku.

3.1.2 Sinkronizacija videozapisa korištenjem QR kodova

Algoritam se sastoji iz dva veća dijela. Prvi dio se odnosi na funkciju pronalaska sinkronizacijske točke promatranog i referentnog videozapisa. Drugi dio se odnosi na procjenu kvalitete videozapisa (čitanje ispuštenih slika promatranog videozapisa u odnosu na referentni videozapis).

Slika 3.1. prikazuje način pronalaska sinkronizirajućeg okvira, na sljedeći način:

1. **Učitavanje videozapisa** – videozapis se ne učitava u cijelosti, nego se postepeno čita okvir po okvir. Algoritam čita okvire rekonstruiranog videozapisa, sve dok ne nađe na prvi okvir čiji QR kod može pročitati.

2. **Pronalazak sinkronizacijske točke** – učitava se okvir po okvir referentnog videozapisa, sve dok se na poklope QR kodovi promatranog okvira i referentnog okvira (slika 3.2.).
3. **Odabir načina provjere sinkroniziranosti** – budući da broj slika u sekundi u oba videozapisa se ne mora podudarati, potrebno je odrediti način sinkronizacije:
 - 1 : 1 sinkronizacija – ukoliko za svaki okvir iz referentnog videozapisa postoji samo jedan okvir iz rekonstruiranog videozapisa (ako imaju jednak broj slika u sekundi), dovoljno je da od prvih pet pročitanih slika se podudaraju tri slike da bi se ostvarila sinkronizacija.
 - 1 : n sinkronizacija – ako je broj slika u sekundi snimljenog videozapisa višekratnik broja slika u sekundi referentnog videozapisa, nužno je da QR kod jednog od n okvira rekonstruiranog videozapisa odgovara jednom okviru promatranog videozapisa. (Primjerice, ukoliko rekonstruirani videozapis ima 60 slika u sekundi, a referentni 30 slika u sekundi, znači da su se duplicirali okviri referentnog u promatranom videozapisu, te za jedan okvir referentnog odgovaraju dva okvira promatranog videozapisa). Takav način treba zadovoljiti za tri od pet referentnih okvira.
 - m : n sinkronizacija – ako broj slika u sekundi snimljenog videozapisa nije višekratnik broja slika referentnog videozapisa (primjerice, u odnosu su 60 : 25), radi se o $m:n$ sinkronizaciji. U tom slučaju, dijele se ta dva broja, i zaokružuju na prvi veći prirodni broj N (3-1). Za svaki okvir u referentnom videozapisu, promatra se N okvira rekonstruiranog videozapisa. Takav način treba zadovoljiti za tri od pet referentnih okvira.

$$N = \frac{n}{m}$$

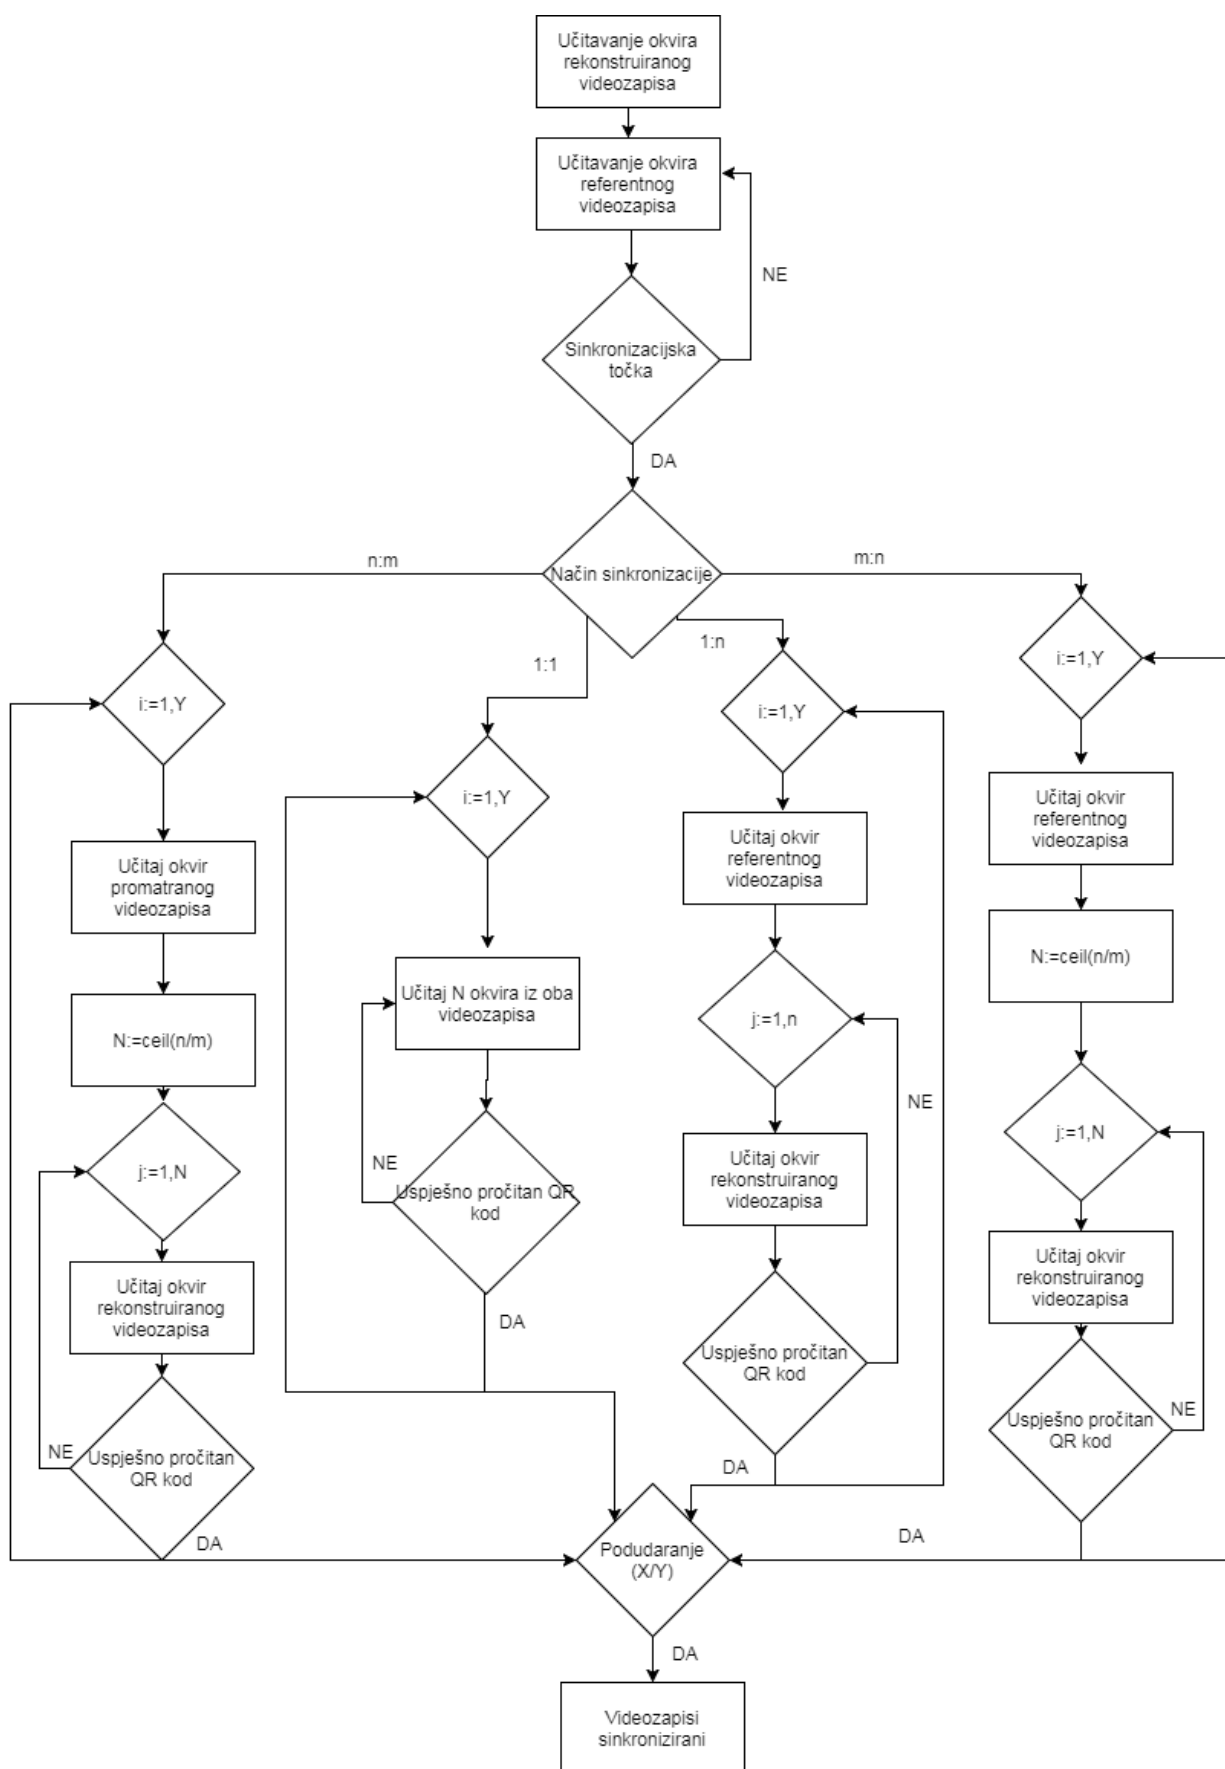
$$N = \frac{60}{25} = 2,4 \approx 3(3-1)$$

- n : m sinkronizacija – ako je broj slika u sekundi snimljenog videozapisa veći od broja slika rekonstruiranog videozapisa. Potrebno je za pet pročitanih QR kodova promatranog videozapisa pronaći najmanje tri odgovarajuća QR koda s referentnog videozapisa unutar $N \cdot 10$ slika referentnog videozapisa (3-2), pri čemu se koristi slična formula kao i za $m:n$ sinkronizaciju:

$$N = \frac{m}{n} \quad (3-2)$$



Sl. 3.1. Prikaz sinkronizirajućih okvira referentnog i rekonstruiranog videozapisa



SI 3.2. Dijagram toka sinkronizacije referentnog i rekonstruiranog videozapisa uz QR kodove

Slika 3.2. prikazuje dijagram toka algoritma sinkronizacije s QR kodovima. Y prikazuje broj slika promatranog videozapisa.

3.1.3 Procjena kvalitete videozapisa korištenjem QR kodova

Nakon uspješno ostvarene sinkronizacije, započinje drugi dio algoritma – procjena kvalitete rekonstruiranog videozapisa. Potrebno je odrediti koliko okvira referentnog zapisa je snimljeno, koji su to okviri, te za svaki od tih okvira dati jedan od tri izvještaja:

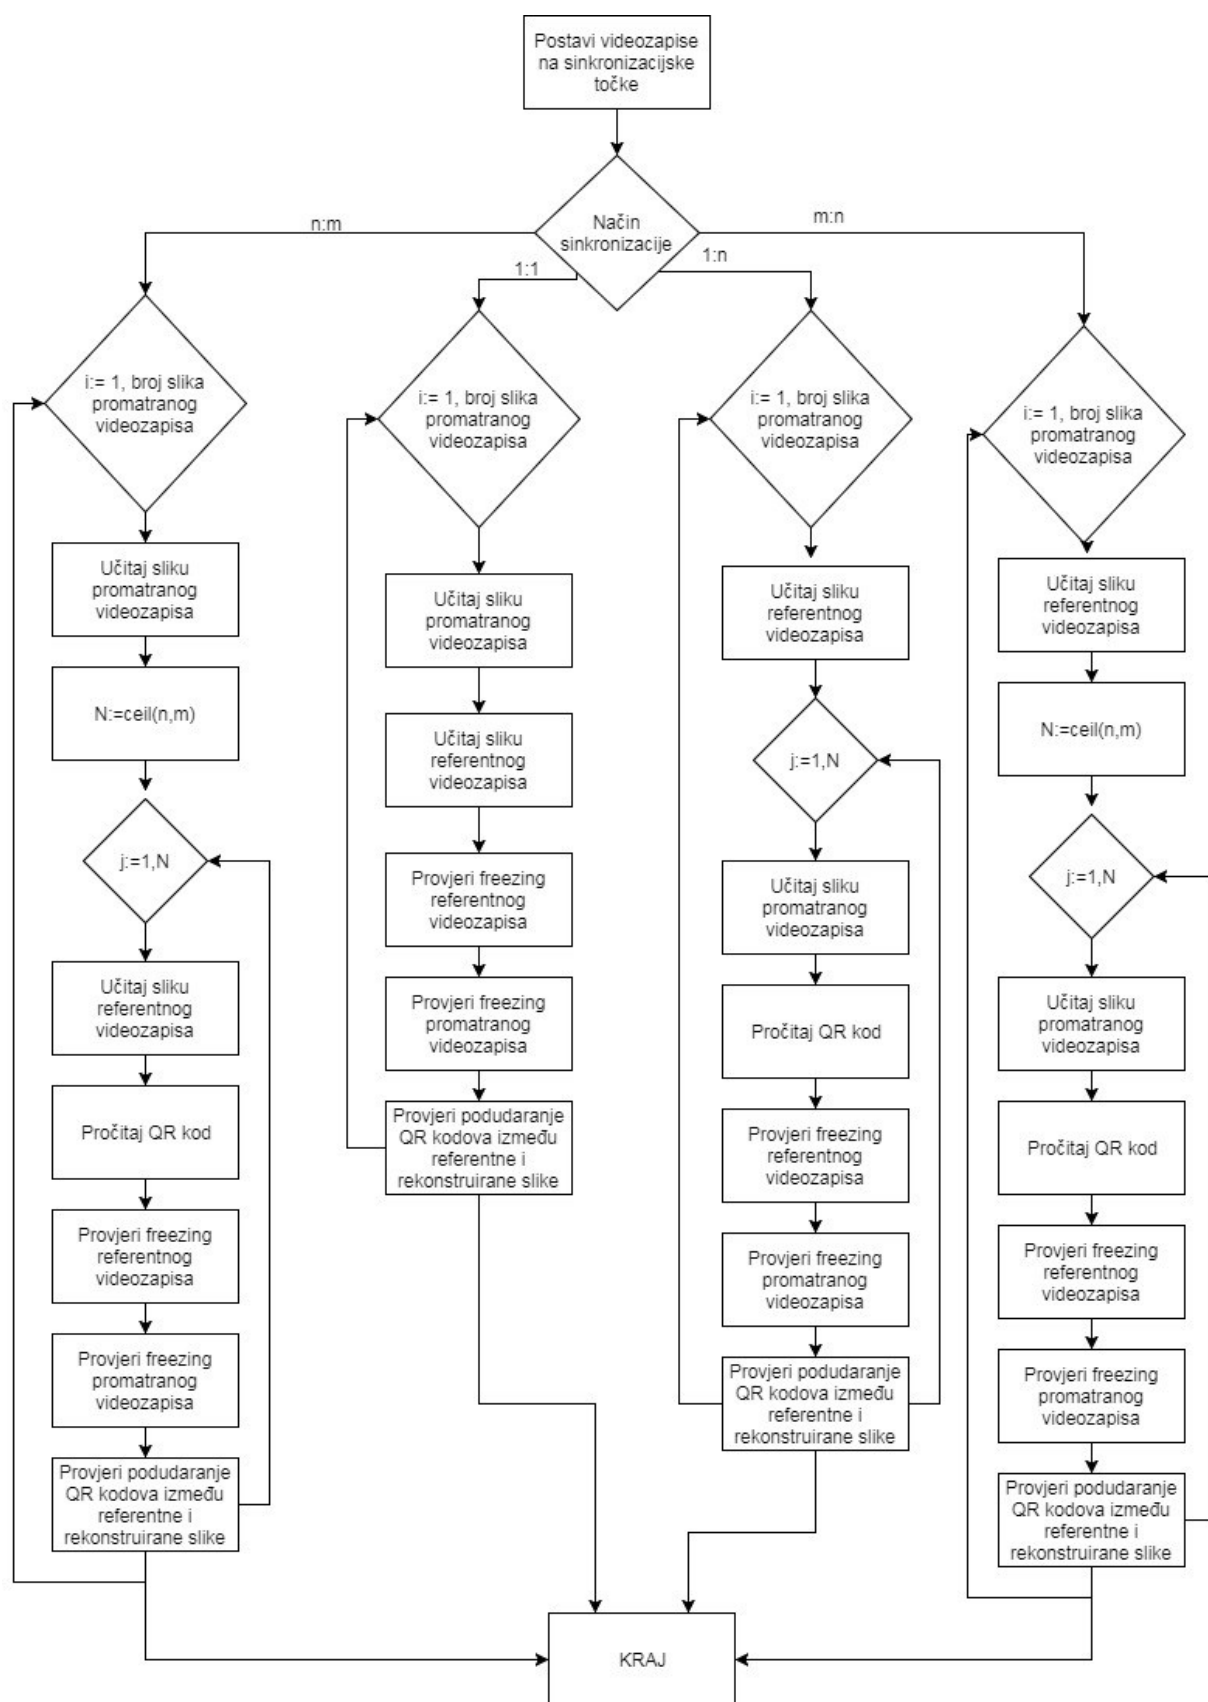
1. okviri se podudaraju
2. okviri se ne podudaraju (ispušten okvir)
3. okvir nije moguće pročitati (ograničenje QR dekodera i/ili nedovoljno kvalitetno snimljen videozapis)

Način rada algoritma je sljedeći:

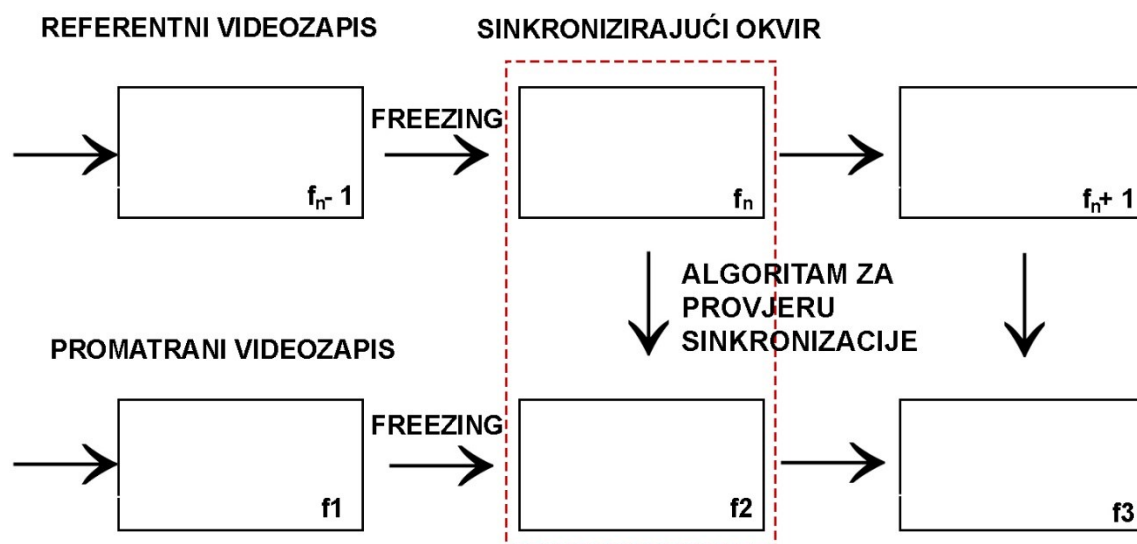
1. **Postavljanje oba videozapisa na sinkronizacijske točke** – kako bi se mogla uspješno izvršiti procjena kvalitete
2. **Odabir načina procjene kvalitete** – u ovisnosti o omjeru broja slika u sekundi referentnog i rekonstruiranog videozapisa, na sličan način kao i za provjeru sinkroniziranosti.
3. **Čitanje QR koda referentnog okvira** – potrebno je prvo provjeriti je li QR dekodirer u mogućnosti pročitati QR kod referentnog okvira. Ukoliko nije, nepotrebno je pokušati čitati QR kod rekonstruiranog okvira.
4. **Procjena kvalitete** – procjena ovisi o odabranom načinu iz točke 2:
 - $1 : 1$ procjena kvalitete – odgovara li pročitani QR kod referentnog okvira QR kodu rekonstruiranog okvira
 - $1 : n$ procjena kvalitete – odgovara li pročitani QR kod jednom od QR kodova n rekonstruiranih okvira
 - $m : n$ procjena kvalitete – odgovara li pročitani QR kod jednom od QR kodova N rekonstruiranih okvira (prema formuli 3-1)
 - $n : m$ procjena kvalitete – odgovara li pročitani QR kod rekonstruiranog videozapisa jednom od QR kodova N referentnih okvira (prema formuli 3-2)
5. **Provjera ispuštenih okvira** – ukoliko su oba QR koda uspješno pročitana, potrebno je utvrditi radi li se o ispuštanju okvira samo kod rekonstruiranog videozapisa, ili je isti slučaj i kod referentnog videozapisa. Ukoliko je jednak broj okvira kod istih

vremenskih oznaka u oba videozapisa ispušten, algoritam mora dati informaciju da nema ispuštenih okvira.

6. **Pohrana informacija** – informacije o podudaranju, različitosti i nemogućnosti čitanja QR koda za pojedini okvir se pohranjuju u tekstualnom formatu, za daljnju analizu.



SI 3.3. Dijagram toka procjene kvalitete rekonstruiranog videozapisa uz QR kodove



SI 3.4. Algoritam provjere ispuštenih slika i evaluacije videozapisa

Na slici 3.4. vidljiv je algoritam koji provjerava postoje li ispuštene slike u videozapisu. On radi na principu provjere identičnosti QR kodova. Provjerava se prvo ukoliko je u referentnom videozapisu došlo do ispuštanja okvira (eng. *freezing*), zatim istu stvar provjerava i u promatranom videozapisu, na način da provjeri prošlu i trenutnu sliku (f_n i f_{n-1}). Ukoliko *freezing* postoji u jednom od dva videozapisa, znači da se narušila kvaliteta i takva informacije se zapisuje u CSV (eng. *comma separated values*) datoteku s informacijom na kojoj slici i u kojem videozapisu se dogodio *freezing*. Algoritam za provjeru sinkronizacije kod QR kodova jednostavno uspoređuje sliku referentnog i rekonstruiranog videozapisa, i ukoliko se slike podudaraju, bilježi se u datoteku podudaranje, a u suprotnom se bilježi da nije došlo do podudaranja vrijednosti QR kodova.

Važno je napomenuti kako se bilježe i neuspješno pročitani QR kodovi, pa je jedno od ograničenja ovakvog algoritma direktno pod utjecajem kvalitete *quirc* algoritma za dekodiranje. Radi ubrzavanja čitanja kodova, slike videozapisa se reskaliraju na manju rezoluciju, točnije 1280x720, koja je pronađena empirijski kao najmanja rezolucija pri kojoj se kodovi čitaju jednako kvalitetno kao i u originalnim rezolucijama (koje su veće od te rezolucije).

3.2 Sinkronizacija i procjena kvalitete metodom N PSNR lokalnih maksimuma

Sljedeće rješenje se odnosi na videozapise koji mogu, a i ne moraju sadržavati QR kod. Metoda je namijenjena sinkroniziranju i procjeni kvalitete videozapisa koji su dohvaćeni pomoću *grabber*-a, uređaja za dohvaćanje slika sa transportnog toka.

3.2.1 Sinkronizacija metodom N PSNR lokalnih maksimuma

PSNR (eng. *Peak signal-to-noise ratio*) je pojam kojim se opisuje odnos maksimalne moguće snage signala i snage degradiranog signala koji utječe na vjernost reprezentacije. Najlakše ga se definira preko srednje kvadratne pogreške. Ukoliko se uzme slika bez šumova, monokromna, veličine $m \times n$, I , te ista takva slika K uz prisutnost šuma, formula za srednju kvadratnu pogrešku glasi:

$$MSE = \frac{1}{m \cdot n} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - K(i, j)]^2 \quad (3-3)$$

Prema tome, PSNR, u decibelima, se definira kao:

$$PSNR = 10 * \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (3-4)$$

Pri čemu MAX_I označava maksimalnu moguću vrijednost osnovnog elementa slike – za monokromnu sliku ta vrijednost je 255.

Prihvatljive vrijednosti za slike sa šumom su iznad 20dB.


Kao što je navedeno, računajući PSNR vrijednost između dvije slike se dobije njihova sličnost. Budući da je ideja sinkronizacije dvaju videozapisa, pronaći slijed od N istih slika, kao optimalno rješenje po brzini i učinkovitosti odabran je PSNR.

Algoritam sinkronizacije metodom N PSNR lokalnih maksimuma, funkcionira na sljedeći način:

1. **Pronalazak N PSNR lokalnih maksimuma** – uzima se prva slika rekonstruiranog videozapisa, i u petlji se prolazi kroz kompletan referentni videozapis, te se uspoređuju slike i bilježi PSNR za svaki uređeni par (p_v, r_v) , pri čemu je p_v slika promatranog videozapisa, a r_v slika referentnog videozapisa
2. **Odabir načina sinkronizacije** - budući da se broj slika u sekundi u oba videozapisa ne mora podudarati, potrebno je odrediti način sinkronizacije:
 - 1 : 1 sinkronizacija – ukoliko za svaki okvir iz referentnog videozapisa postoji samo jedan okvir iz rekonstruiranog videozapisa (ako imaju jednak broj slika u sekundi),

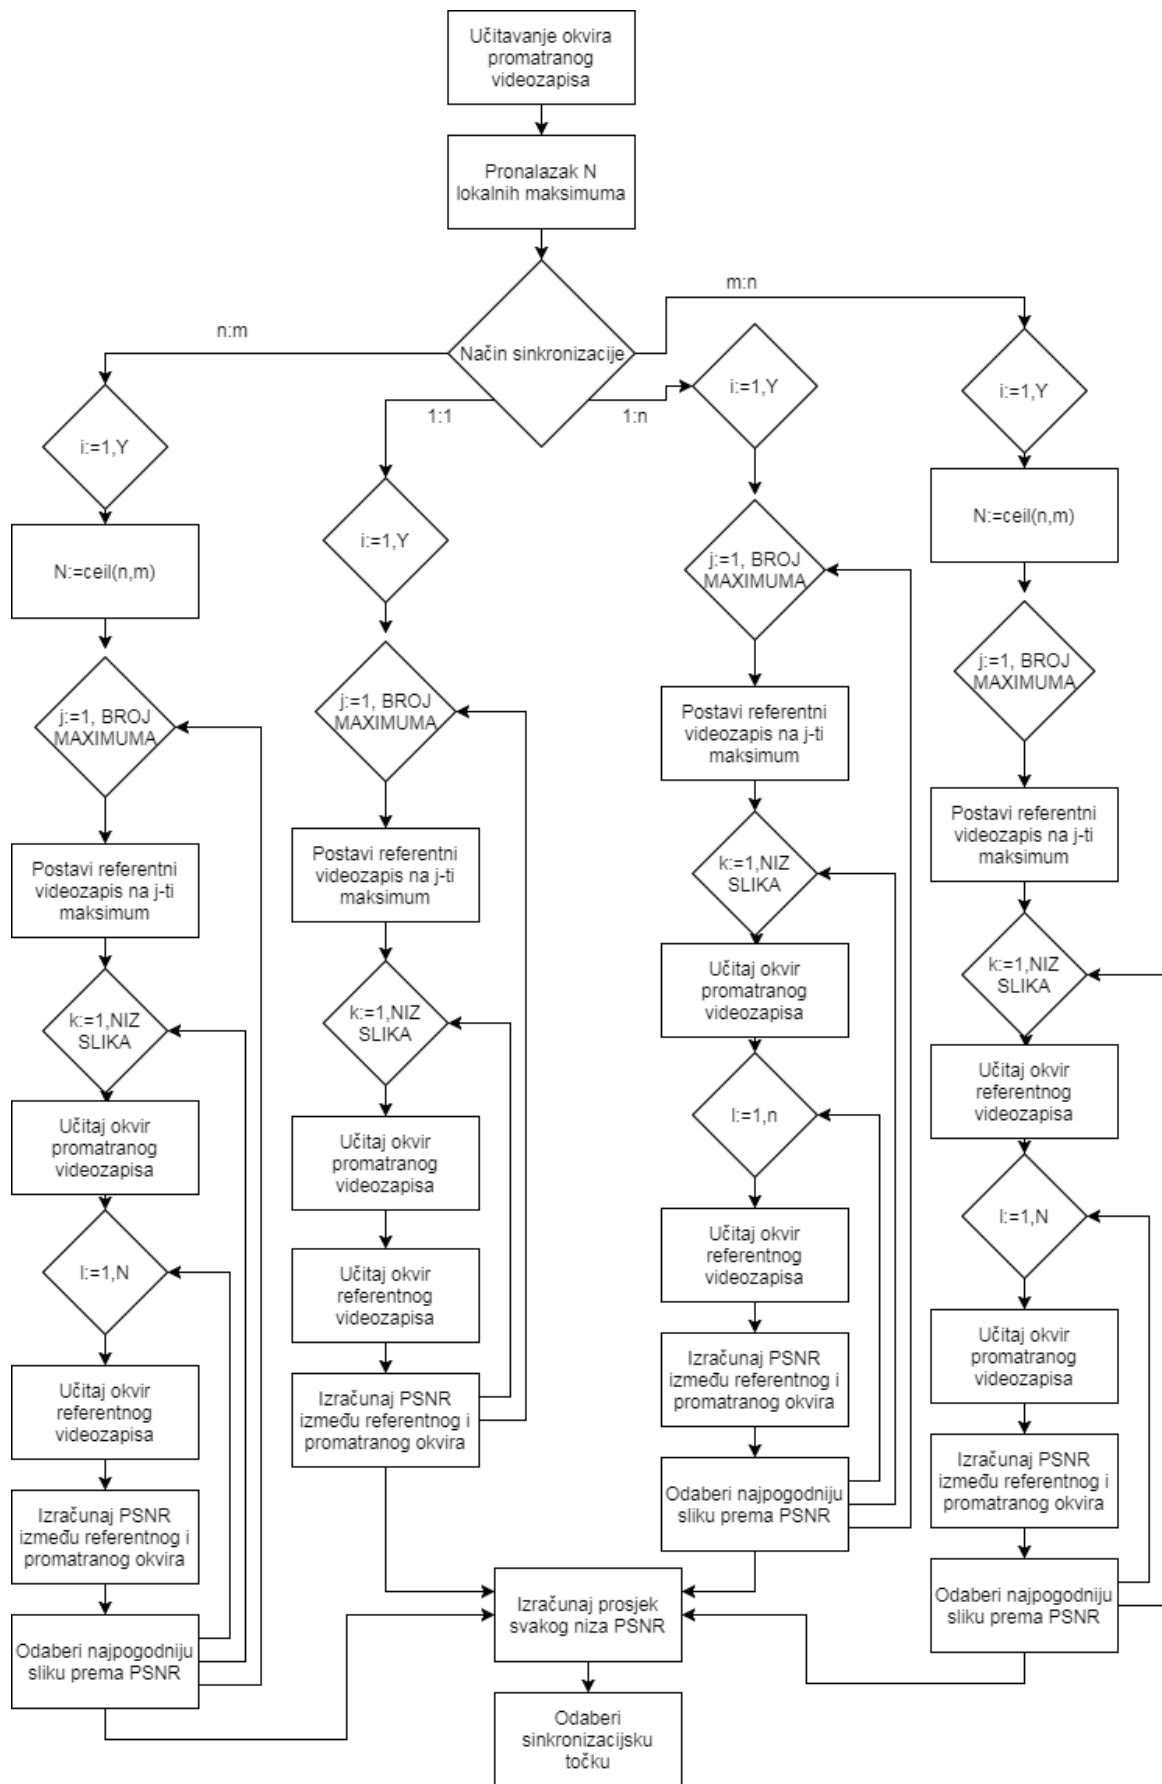
točno jedan okvir iz rekonstruiranog videozapisa se provjerava s jednim okvirom iz referentnog videozapisa.

- $1 : n$ sinkronizacija – ako je broj slika u sekundi snimljenog videozapisa višekratnik broja slika u sekundi referentnog videozapisa, uzima se najveća vrijednost PSNR-a uspoređujući jedan okvir referentnog videozapisa s n okvira rekonstruiranog videozapisa.
 - $m : n$ sinkronizacija – ako broj slika u sekundi snimljenog videozapisa nije višekratnik broja slika referentnog videozapisa (primjerice, u odnosu su $60 : 25$), radi se o $m:n$ sinkronizaciji. U tom slučaju, dijele se ta dva broja, i zaokružuju na prvi veći prirodni broj N (3-1). Za svaki okvir u referentnom videozapisu, promatra se N okvira rekonstruiranog videozapisa, te se računa PSNR za svaki od slučajeva i uzima najveća vrijednost.
 - $n : m$ sinkronizacija – ako je broj slika u sekundi snimljenog videozapisa veći od broja slika rekonstruiranog videozapisa, prema formuli (3-1) se računa prirodan broj N , te za svaki okvir rekonstruiranog videozapisa, promatra se N okvira referentnog videozapisa, te traži okvir s najvećom vrijednošću PSNR u usporedbi s promatranim okvirom.
3. **Računanje PSNR-a za niz od M slika za svaki od N PSNR lokalnih maksimuma** – jednom kad se uoči N lokalnih maksimuma, računa se PSNR za narednih M slika u promatranom i referentnom videozapisu
4. **Određivanje sinkronizacijske točke** – Nakon što za svaki od N PSNR maksimuma, postoji slijed od M slika, računa im se srednja vrijednost, te maksimum čiji slijed ima najveću srednju vrijednost postaje sinkronizacijska točka (ukoliko je veći od minimalnog praga PSNR vrijednosti)



SI 3.5. Način rada algoritma potrage za najvećom PSNR vrijednošću

Na slici iznad (3.5.), prikazan je rad algoritma koji uspoređuje okvir jednog videozapisa s N okvira drugog videozapisa. Ukoliko je, primjerice, $N = 3$, te za jedan okvir referentnog zapisa odgovara dva do tri okvira promatranog videozapisa, algoritam uspoređuje okvir referentnog videozapisa sa sva tri okvira promatranog videozapisa. Kao primjer, uzmimo da od ta tri okvira, drugi promatrani ima najveću PSNR vrijednost u usporedbi s referentnim okvirom. Tada se, za usporedbu idućeg okvira, pokazivač postavlja na okvir iza onog s najvećim PSNR-om u promatranom zapisu, te se idući referentni okvir opet nastavlja uspoređivati s narednih N promatranih okvira. Jednom kad se okviri usporede i da im se značenje (sličnost/različitost/ispuštanje okvira), više se te okvire ne uspoređuje. Ovakav rad algoritma ima složenost $O(N*n)$.



SI 3.6. Dijagram toka sinkronizacije putem algoritma N PSNR lokalnih maksimuma

Na slici 3.6. vidljiv je dijagram toka sinkronizacije putem algoritma N PSNR lokalnih maksimuma. Konstanta „BROJ MAKSIMUMA“ predstavlja broj maksimuma koji će algoritam tražiti u videozapisu. Y predstavlja ukupan broj slika rekonstruiranog videozapisa, dok konstanta „NIZ SLIKA“ predstavlja broj koji označava slijed slika za svaki PSNR maksimum čiji će se PSNR-ovi računati, da bi se na kraju računao prosjek za svaki niz slika, te kao sinkronizacijska točka odabrala ona s najvećim prosjekom.

3.2.2 Procjena kvalitete pomoću PSNR vrijednosti i detekcija ispuštanja okvira

Jednom kad se uspostavi sinkronizacija dvaju videozapisa, vrši se procjena kvalitete videozapisa koji je dohvaćen s *grabber* uređaja ili sadrži neki drugi oblik degradacije (CRF/QP/Packet Loss/Blocking). Algoritam procjene kvalitete radi na sljedećem principu:


1. **Postavljanje oba videozapisa na sinkronizacijske točke** – kako bi se mogla uspješno izvršiti procjena kvalitete
2. **Odabir načina procjene kvalitete** – u ovisnosti o omjeru broja slika u sekundi referentnog i rekonstruiranog videozapisa, na sličan način kao i za provjeru sinkroniziranosti.
3. **Procjena kvalitete** – procjena ovisi o odabranom načinu iz točke 2:
 - 1 : 1 procjena kvalitete – odgovara li učitani okvir referentnog videozapisa okviru rekonstruiranog videozapisa: prvotno se provjerava *freezing* između trenutnog i prošlog okvira referentnog zapisa, trenutnog i prošlog okvira rekonstruiranog videozapisa. Ukoliko ne postoji *freezing*, računa se PSNR vrijednost tih dvaju okvira te usporedbom s minimalnim zadovoljavajućim pragom).
 - 1 : n procjena kvalitete – odgovara li učitani okvir referentnog okvira jednom od n okvira rekonstruiranog videozapisa: prvotno se provjerava *freezing* između trenutnog i prošlog okvira referentnog zapisa, trenutnog i prošlog okvira rekonstruiranog videozapisa. Ukoliko ne postoji *freezing*, računa se PSNR vrijednost za svaki od okvira iz rekonstruiranog videozapisa, pronalazi se okvir s najvećim PSNR-om, te uspoređuje s minimalnim zadovoljavajućim pragom)
 - m : n procjena kvalitete – odgovara li učitani okvir referentnog okvira jednom od N okvira (prema formuli 3-1) rekonstruiranog videozapisa: prvotno se provjerava *freezing* između trenutnog i prošlog okvira referentnog zapisa, trenutnog i prošlog okvira rekonstruiranog videozapisa. Ukoliko ne postoji *freezing*, računa se PSNR

vrijednost za zvaki od okvira iz rekonstruiranog videozapisa, pronalazi se okvir s najvećim PSNR-om, te uspoređuje s minimalnim zadovoljavajućim pragom)

- $n : m$ procjena kvalitete – odgovara li učitani okvir rekonstruiranog videozapisa jednom od N (prema formuli 3-1) okvira referentnog videozapisa: prvotno se provjerava *freezing* između trenutnog i prošlog okvira referentnog zapisa, trenutnog i prošlog okvira rekonstruiranog videozapisa. Ukoliko ne postoji *freezing*, računa se PSNR-a za svaki od okvira iz referentnog videozapisa, pronalazi se okvir s najvećim PSNR-om, te uspoređuje s minimalnim zadovoljavajućim pragom)

4. **Pohrana informacija** – informacije o identičnim okvirima, niskoj PSNR vrijednosti između okvira, ispuštanju okvira u referentnom ili rekonstruiranom videozapisu za pojedini okvir se pohranjuju u tekstualnom formatu, za daljnju analizu.

Na slici 3.7. prikazana je vizualna prezentacija gore opisanog algoritma. Shema je slična kao i za evaluaciju uz QR kodove. Razlike u evaluaciji su u algoritmu usporedbe slika, pri čemu se u ovom slučaju koristi PSNR, te detekcija ispuštenih okvira kao mjerilo kvalitete rekonstruiranog videozapisa.



SI 3.7. Dijagram toka procjene kvalitete pomoću PSNR vrijednosti i detekcija ispuštenih okvira

3.3 Korištene tehnologije, biblioteke, način korištenja

Za izradu završnog rješenja, korišteni su programski jezici C i C++, alati za modeliranje MATLAB, te biblioteke otvorenog koda *ffmpeg*, *opencv*, *quirc*. Za generiranje sekvenci prvenstveno su korišteni MATLAB, *ffmpeg*, NodeJS, te njegovi moduli GraphicsMagic, qr-image, imagemagick. Za pregledavanje videozapisa korišteni su VLC player, Windows Media Player, mpv player.

Rješenje je napravljeno u obliku dvije dinamičke biblioteke (odvojeno za sinkronizaciju i evaluaciju pomoću QR koda i bez koda).

Rješenje se također može koristiti u naredbenom retku, ukucavanjem imena programa, i proslijeđujući mu dva parametra – apsolutni put do referentnog videa, i apsolutni put do rekonstruiranog videozapisa.

4 VREDNOVANJE I DISKUSIJA RADA ALGORITAMA ZA SINKRONIZACIJU I EVALUACIJU VIDEOZAPISA

Nakon, a i tokom implementacije algoritma, bilo ga je potrebno detaljno testirati, kako bi se uvidjela kvaliteta, brzina, prednosti i nedostaci.

4.1 Rezultati i analiza algoritma sinkronizacije i evaluacije uz QR kod

Glavne karakteristike ovog algoritma, ovise o izabranoj biblioteci otvorenog koda za čitanje brzo-odgovarajućih kodova, a to su brzina i sposobnost/kvaliteta čitanja QR koda.

Na ukupno trideset šest testnih sekvenci (šest različitih videozapisa s različito generiranim *frame rate*-om, da bi se ispunili slučajevi 1:1, 1:n i m:n), od čega osamnaest u 4K rezoluciji (3840×2160) i osamnaest u HD rezoluciji (1920×1080) snimljeno mobitelom Samsung Galaxy S7 i referentnim sekvencama u HD rezoluciji (1920×1080), testirana je brzina i kvaliteta algoritma. Također, pomoću *grabber* uređaja, snimljeno je 6 sekvenci s televizijskog prijemnika koji sadrže QR kod, uz rezoluciju 1920×1080 i 30 okvira u sekundi, koji ih reskalira na rezoluciju 640×480:


- prije samog čitanja QR koda, okviri veće rezolucije od 1280×720, reskalirani su na tu rezoluciju, zbog identičnog ponašanja biblioteke na toj i većim rezolucijama, ali veće brzine čitanja koda
- videozapisi rezolucije manje od 1280×720 su ostali netaknuti

Tab 3.12. Prikaz rezultata čitanja tokom sinkronizacije i evaluacije putem QR koda

<i>Videozapis</i>	Broj pročitanih slika za sinkronizaciju	Ukupno vrijeme čitanja (ms)	Prosječno vrijeme čitanja (ms)	Uspješnost čitanja (%)
<i>bridge</i>	2340	687024	293,6	95,6
<i>desert</i>	1732	532590	307,5	97,4
<i>waterfall</i>	955	305122	319,5	91,5
<i>ignacio</i>	3307	1006981	304,5	98,6
<i>orlando</i>	1426	441917	309,9	94,3
<i>nature</i>	1409	446089	316,6	92,5
UKUPNO:	11169	3446753	308,6	94,9

Sveukupno je za testiranje sinkronizacije pročitano 11169 okvira. Prosječno vrijeme čitanja QR koda pojedinog okvira za rezoluciju 1280×720 je 308,6 milisekundi, odnosno približno tri slike u sekundi. Treba imati na umu da složenost algoritma za evaluaciju je $O(N*n)$, pri čemu se N dobija formulom (3-1). Uspješnost čitanja je u prosjeku 94,9%, no obzirom da su videozapisi snimani kamerom, postoji mogućnost da frekvencija promjene slika zapisa na računalu i frekvencija

uzorkovanja kamerom mobitela imaju pomak u fazi. Takva situacija uzrokuje nečitljiv QR kod kao na slici 3.8.



SI 3.8. Primjer nečitljivog QR koda (lijevo) i čitljivog koda (desno)

Algoritam kao rješenje daje informaciju o ispuštenim okvirima u referentnom i rekonstruiranom videozapisu, postoji li poklapanje za svaki okvir te je li uspješno pročitani QR kod u jednom i drugom videozapisu. Algoritam se pokazao kvalitetan i potpuno točan i uvijek daje ispravne rezultate za sve uspješno pročitane okvire.

Glavno ograničenje i nedostatak ovog algoritma je u *quirc* biblioteci za čitanje QR koda, prvenstveno i o kojoj uvelike ovisi brzina, mogućnost sinkronizacije i kvaliteta evaluacije videozapisa.

```
ms,value
1733.333333,0
1766.666667,0
1833.333333,0
1900.000000,0
1966.666667,0
2033.333333,0
2100.000000,0
2166.666667,0
2233.333333,0
2300.000000,0
2366.666667,0
2433.333333,0
2500.000000,0
2566.666667,0
2633.333333,0
2700.000000,0
2766.666667,0
2833.333333,0
2866.666667,0
2933.333333,0
```

SI 3.9. Primjer rezultata algoritma evaluacije videozapisa uz QR kod

Rezultati algoritma su formatirani u obliku CSV datoteke, kao na slici 3.9. U prvom stupcu se prikazuje milisekunda referentnog zapisa, a drugi stupac predstavlja vrijednost koja označava informaciju o istom okviru rekonstruiranog videozapisa. Za videozapis s QR kodom su mogući sljedeći ishodi:

- 0 – okviri su identični
- 1 – dogodilo se ispuštanje okvira u promatranom videozapisu
- 2 – QR kod referentnog okvira nije uspješno pročitano
- 3 – QR kod promatranog okvira nije uspješno pročitano

4.2 Rezultati i analiza algoritma sinkronizacije i evaluacije korištenjem PSNR-a

Za testiranje kvalitete rada algoritma koji koristi PSNR kao referencu za procjenu kvalitete, korišteni su videozapisi koji su navedeni u sljedećem poglavlju, u potpoglavlju „6.1.2 Priprema i obrada videozapisa za testiranje“. Osim tih videozapisa, pomoću *grabber* uređaja kreirani su realni slučajevi za testiranje, tako da je algoritam testiran u kontroliranom i stvarnom okruženju.

Rezultati algoritma korištenjem N PSNR lokalnih maksimuma prikazani su u tablici 3.13. Za svaki od pet pronađenih maksimuma uzima se narednih deset okvira za testiranje. Rezultati su prikazani tablično i grafički:


Nasumično su odabrani sinkronizirajući okviri u referentnom videozapisu, te su prikazani neki od rezultata (jedan za svaki videozapis; sporopromjenjive (HoneyBee videozapis), normalne (Beauty videozapis) i brzopromjenjive sekvence (Bosphorus videozapis)), za različite stupnjeve degradacije promatranog videozapisa:

Slučajevi sinkronizacije i evaluacije $1:n$ i $m:n$ koriste sličan način u odabiru okvira, rezultatski se moraju poklapati, te su stoga prikazani samo rezultati za situaciju $1:n$.

Tab 3.13. Vrijednosti PSNR za 10 okvira svakog lokalnog maksimuma, Beauty videozapis, $1:n$

Bea											
Lok.. Max CRF	PSNR										
	30		Frame	37							
	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	
1.	25,99	25,23	24,77	24,93	25,57	26,26	26,66	25,32	24,44	23,45	25,26
2.	29,35	28,92	28,29	27,26	26,86	27,08	28,18	28,59	28,88	26,98	28,04
3.	26,62	26,90	25,99	25,21	24,80	24,98	25,65	26,30	26,66	25,33	25,84
4.	28,84	28,23	27,21	26,76	26,96	28,06	28,53	28,85	26,93	25,77	27,62

5.



SI 3.10. Graf vrijednosti PSNR za svaki od lokalnih maksimuma, Beauty videozapis


Na videozapisu Beauty, prosječna vrijednost sinkronizirajućeg lokalnog maksimuma je 35.62, što je za 27% bolje od idućeg potencijalno sinkronizirajućeg lokalnog maksimuma (28.04). Svi okviri i prosjeci prelaze minimalni postavljeni prag PSNR koji osigurava da se radi o istim videozapisima. Za promatranu sekvencu je sinkronizirajući okvir uspješno pronađen.

Tab 3.14. Vrijednosti PSNR za 10 okvira svakog lokalnog maksimuma, Bosphorus videozapis,

I:n

Bos

Lok Max CRF	PSNR										Average
	40		Frame	137							
	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	
1.	27,57	27,24	27,64	27,27	27,07	27,51	27,03	26,87	27,41	27,14	27,27
2.	28,90	28,75	29,20	28,76	28,64	29,0822	28,62	28,523	29,08	28,64	28,82
3.	30,24	30,12	30,29	30,30	30,13	30,25	30,22	30,05	30,18	30,19	30,20
4.	27,28	26,77	27,45	27,10	26,63	27,26	26,99	26,66	27,41	27,13	27,07
5.	29,02	28,42	29,06	28,90	28,30	28,89	28,7660	28,27	28,95	28,88	28,74



SI 3.11. Graf vrijednosti PSNR za svaki od lokalnih maksimuma, Bosphorus


Na slici 3.11. prikazan je graf PSNR vrijednosti za videozapis Bosphorus, te nasumično odabran sinkronizirajući okvir. Radi se o brzopromjenjivoj sekvenci, zajedno se kreću i kamera koja snima scenu, i objekti na njoj. U tablici 3.14 vidi se razlika sinkronizirajućeg okvira odnosu na susjedne okvire (~5%).

Tab 3.15. Vrijednosti PSNR za 10 okvira svakog lokalnog maksimuma, HoneyBee videozapis,

1:n

Hon


Lok. Max CRF	PSNR										Average
	30		Frame	29							
	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	
1.	37,74	37,66	37,70	37,45	37,73	37,60	37,76	37,47	37,84	37,67	37,66
2.	36,30	36,71	36,73	36,96	36,59	36,39	36,40	36,37	36,30	36,34	36,51
3.	36,08	35,99	36,09	36,14	36,15	34,93	35,34	35,59	36,18	35,88	35,84
4.	36,40	36,10	36,15	35,34	35,16	35,69	36,17	36,06	35,70	35,15	35,79
5.	36,74	36,94	36,86	36,70	36,28	36,66	36,20	36,54	36,29	36,29	36,55



SI 3.12. Graf vrijednosti PSNR za svaki od lokalnih maksimuma, HoneyBee videozapis, 1:n

HoneyBee je sporopromjenjiv zapis, u kojem je pozadina gotovo statična, a aktivnost se vidi na jednom objektu (pčela), koji je dimenzijama izrazito malen u odnosu na ostatak scene. Iz tablice 3.15., vidi se da je razlika minimalna (manja od 1 dB), odnosno oko 3%, no svejedno je prepoznati okvir ispravan.

Za svaki od preostalih videozapisa, algoritam je uspješno pronašao sinkronizirajući okvir, do stupnja degradacije $CRF = 45$. Ovakav konstantni faktor stope označava poprilično lošu kvalitetu videozapisa, kakvu se može vidjeti na slici 3.13. CRF je uobičajena skala za velik broj video enkodera, koja predstavlja konstantu kvalitete između 0 i 51, pri čemu manja vrijednost označava veću kvalitetu.




SI 3.13. Primjer okvira videozapisa konstantnog faktora stope 45

Algoritam uspješno izvršava sinkronizaciju u kontroliranim uvjetima.

Za videozapise s *grabber* uređaja, za slučajeve $n:m$ i $1:1$, dana su tri primjera rješenja za normalan, brzopromjenjiv i sporopromjenjiv zapis. *Frame rate* referentnog videozapisa je 60 okvira u sekundi, dok promatrani videozapis sadrži 15 okvira u sekundi.

Tab 3.16. Vrijednosti PSNR za 10 okvira svakog lokalnog maksimuma, *Beauty* videozapis, $m:n$

	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	Average
1.	23,00	22,23	21,32	21,15	20,44	20,54	21,42	20,92	20,61	20,75	21,24
2.	27,00	25,21	25,11	27,07	25,84	25,54	25,71	25,78	25,63	25,60	25,85
3.	27,00	25,21	25,11	27,07	25,84	25,54	25,71	25,78	25,63	25,60	25,85
4.	27,00	25,21	25,11	27,07	25,84	25,54	25,71	25,78	25,63	25,60	25,85
5.	24,57	25,21	25,11	27,07	25,84	25,54	25,71	25,78	25,63	25,60	25,61




SI 3.14. Graf vrijednosti PSNR za svaki od lokalnih maksimuma, *Beauty* videozapis, $m:n$ sinkronizacija

Budući da uređaj za dohvaćanje slika vrši degradaciju i reskaliranje slike, PSNR je unutar očekivanih vrijednosti. Tri maksimuma imaju jednake vrijednosti jer se radi o istim okvirima. Obzirom da se prema formuli (3-1) izračunava N , a radi se o situaciji u kojoj promatrani videozapis ima manje okvira od referentnog videozapisa, zapravo se jedan promatrani okvir uspoređuje s N referentnih okvira. Kad se pronade k -ti najviši PSNR u skupu od N , za usporedbu s idućim okvirom, referentni videozapis se postavlja na $k+1$ okvir. Tako dolazi do preklapanja rješenja.

Tab 3.17. Vrijednosti PSNR za 10 okvira svakog lokalnog maksimuma, *Bosphorus* brzopromjenjivi videozapis, $m:n$

	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	Average
1.	25,58	25,41	25,46	25,40	25,50	25,56	25,60	25,58	25,56	25,82	25,55
2.	25,58	25,41	25,46	25,40	25,50	25,56	25,60	25,58	25,56	25,82	25,55
3.	25,58	25,41	25,46	25,40	25,50	25,56	25,60	25,58	25,56	25,82	25,55
4.	24,17	25,41	25,46	25,40	25,50	25,56	25,60	25,58	25,56	25,82	25,41
5.	25,13	25,41	25,46	25,40	25,50	25,56	25,60	25,58	25,56	25,82	25,50




SI 3.15. Graf vrijednosti PSNR za svaki od lokalnih maksimuma, Bosphorus videozapis, m:n

Bosphorus videozapis predstavlja brzopromjenjivu sekvencu. Obzirom da se, kao i u prethodnom slučaju, vrši potraga za najadekvatnijim okvirom prema PSNR vrijednosti, tri rezultata imaju identične vrijednosti, što je samo potvrda da u neposrednoj okolini, ne postoji niz okvira koji bolje odgovara promatranom videozapisu.

Tab 3.18. Vrijednosti PSNR za 10 okvira svakog lokalnog maksimuma, HoneyBee sporopromjenjivi videozapis, m:n

	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	Average
1.	28,00	28,10	28,23	28,17	28,17	27,95	27,99	27,84	27,66	27,12	27,92
2.	28,00	28,08	28,20	28,17	28,15	27,92	27,96	27,81	27,62	27,06	27,90
3.	28,00	28,08	28,20	28,17	28,15	27,92	27,96	27,81	27,62	27,06	27,90
4.	28,00	28,08	28,20	28,17	28,15	27,92	27,96	27,81	27,62	27,06	27,90
5.	28,00	28,08	28,20	28,17	28,15	27,92	27,96	27,81	27,62	27,06	27,90



SI 3.16. Graf vrijednosti PSNR za svaki od lokalnih maksimuma, HoneyBee videozapis, m:n

Kod sporopromjenjivih zapisa, glavni je problem što su PSNR vrijednosti susjednih okvira vrlo slične, stoga postoji mogućnost da se računanjem PSNR-a kao sinkronizirajući okvir dobije jedan od susjednih okvira.

Evaluacija se računa PSNR-om na sličan način kao i sinkronizacija. Informacije se pohranjuju u CSV datoteku, i izgledaju kao na slici 3.9. No, ishodi u odnosu na algoritam s QR kodom su nešto drukčiji:

- 0 – okviri su identični
- 1 – dogodilo se ispuštanje okvira u promatranom videozapisu
- 2 – dogodilo se ispuštanje okvira u referentnom videozapisu
- 3 – nema informacije o referentnom okviru (primjerice ako rekonstruirani videozapis ima manje okvira nego referentni)
- 4 – PSNR je ispod minimalnog praga (okviri se ne poklapaju ili je loša kvaliteta slike u pitanju)

Primjer okvira jednog i drugog sinkroniziranog videozapisa, moguće je vidjeti na slici 3.16.



SI 3.17. Primjer okvira originalnog(gornja slika) i *grabbanog* videozapisa(donja slika)

5 METODE POKUŠAJA I POGREŠKE

U procesu dolaska do glavnog rješenja, postojale su mnoge prepreke. Pretpostavke s kojima se započinjao rad nisu uključivale rješenja na sve probleme na koje se nailazilo. Pretpostavke koje su bile točne, za sobom su nosile određene nedostatke, dok su neke od pretpostavki bile netočne. U ovom poglavlju bit će objašnjeni svi postupci koji su vodili od ideje, pretpostavki, koncepta, matematičkih modela, algoritamskih rješenja do glavnog rješenja.

5.1 Tehnike obrade i manipulacije videozapisa i slika

U ovom potpoglavlju su opisani načini obrade slika i videozapisa, te korištene tehnologije.

5.1.1 Obrada slika za pojednostavljena rješenja

Za kreiranje svakog od rješenja, prije svega je napravljeno idejno rješenje u MATLAB-u. MATLAB je programski jezik visoke razine i interaktivna okolina za numeričko i matrično računanje, te za vizualizaciju i programiranje. Koristi se najčešće za obradu signala, obradu sustava kontrole, ispitivanja i mjerenja i računalne financije. Sadrži niz ugrađenih funkcionalnosti i biblioteka koji omogućuju korisniku da na brz i dosta jednostavan način u kratkom roku dođe do željenog odgovora ili rješenja. Obzirom da je su za sve od navedenih metoda potrebne biblioteke za obradu slike, koje MATLAB ima „van kutije“ (eng. *out-of-the-box*), taj računalni program je idealno rješenje za testiranje i uvid u moguće rješenje.

5.1.2 Priprema i obrada videozapisa za testiranje

U okviru testiranja, potrebno je izgenerirati testne sekvence videozapisa. UltraVideo Group [17] je omogućio skup od 6 videozapisa visoke kvalitete (1080p ili 4k UHD), različite bit-ne dubine, formata i zapisa u kontejner, te je od originalnih videozapisa stvoreno mnoštvo degradiranih videozapisa. Za promjenu kvalitete videozapisa korišten je alat *ffmpeg*, program naredbene linije za transkodiranje multimedijских datoteka. Videozapisima bez gubitaka stvorene su degradirane kopije mijenjajući konstantni faktor stope (eng. *Constant Rate Factor – CRF*), te kvantizacijski faktor (eng. *Quantization Parameter – QP*) koji omogućuju koderu pokušaj postizanja određene izlazne kvalitete za cijelu datoteku, kad je veličine datoteka nebitna. Takav pristup omogućuje maksimalnu efektivnost kompresije. Svaka slika videozapisa dobija stopu bit-ova (eng. *bitrate*) koja treba biti zadržana kroz cijeli videozapis. Nedostatak je što se ne može odrediti specifična veličina datoteke, niti se može odrediti željena bit-stopu i veličina videozapisa.

Razlika kvantizacijskog parametra nad konstantnim faktorom stope je što je određivanjem konstantnog kvantizacijskog parametra, on konstantan za svaki makroblok, dok određivanjem

konstantnog faktora stope, se određuje kvantizacijski parametar prema količini pokreta u jednoj slici videozapisa, ali može biti podešen od strane drugih svojstava. Glavna ideja CRF-a je da omogući vizualnu kvalitetu gotovo istu kao i kvantizacijski parametar s istom vrijednošću, ali to nije potpuno identična jednadžba.

Osim promjene gore navedenih parametara, mijenjan je i koder. Stvoreni su zapisi korištenjem MPEG2, MPEG4 i HEVC, te su spremeni u MP4 kontejner.

```
ffmpeg -f rawvideo -r 120 -vcodec rawvideo -s 1920x1080 -pix_fmt yuv420p -i "%a"
-c:v mpeg4 -qscale:v X "MPEG4\\%%~na_qX.mp4"
```

SI 4.1. Primjer naredbe za pretvorbu iz originalnog videozapisa u MPEG4 kvantizacijskim parametrom X

Na slici 4.1., objašnjen je način pretvorbe originalnog videozapisa u MPEG4 pomoću kvantizacijskog parametra, pri čemu:

- ffmpeg – naredba za poziv ffmpeg unutar naredbene linije
- -f – naredba koja forsira željeni ulazni ili izlazni format
- -r – naredba koja forsira željenu stopu slika u sekundu (eng. *frame rate*)
- -vcodec – naredba koja forsira željeni video codec
- -s – naredba za postavljanje veličine slike (rezolucije)
- -pix_fmt – naredba za postavljanje formata osnovnog elementa slike
- -i – ulazni put do datoteke
- -c:v – naredba za odabir enkodera, ukoliko je korištena prije izlazne datoteke ili dekodera, ukoliko je korištena prije ulazne datoteke
- -qscale:v:X – naredba za određivanje kvantizacijskog parametra videozapisa
- mjesto spremanja izlazne datoteke, ime datoteke i format + kontejner

Postoje još mnoge naredbe za obradu videozapisa, od kojih su korištene:

- -preset – određuje brzinu obrade, utječe na kvalitetu obrade
- -crf – određuje konstantan faktor stope

Stvorena je serijska skripta (eng. *batch script* - *.bat*), koja je obradila sve videozapisa s određenim videokoderom, formatom, rezolucijom, formatom osnovnog elementa slike, kvantizacijskim parametrom/konstantnim faktorom stope.

```
for %%a in (*.*) do ffmpeg -f rawvideo -r frame_rate -vcodec videocodec -s
rezolucija -pix_fmt pixel_format -i "%%a" -c:v encoder -qscale:v X
"MPEG4\%%~na_qX.mp4"

pause
```

SI 4.2. Batch skripta za oblikovanje, degradaciju i spremanje svih ulaznih videozapisa pomoću željenih parametara

Od originalnih videozapisa, sačinjeni su degradirani videozapisi. Stupnjeve degradacije, te tip degradacije može se vidjeti u tablici 4.1. Osim tipa degradacije, mijenjan je i enkoder. Korišteni su enkoderi MPEG2, MPEG4 i HEVC, te je za svaki videozapis korišten MP4 kontejner. Većina videozapisa je stvorena u više *frame rate* oblika: ukoliko se uzme da referentni videozapis ima N sličica u sekundi, degradirani i nedegradirani videozapisi su stvoreni u N , N/M , $N*K$, N/K , $N*K + M$ sličica u sekundi, pri čemu je K cjelobrojni višekratnik broja N , a M nije cjelobrojni višekratnik broja N .

Tab 4.1. Popis tipova i stupnja degradacije koji su napravljeni za testne sekvence videozapisa

Tip degradacije	Vrijednost degradacije
Konstantni faktor stope (CRF)	0
	18
	25
	30
	35
	40
	45
	50
Kvantizacijski parametar (QP)	0
	10
	13
	15


20

25

5.2 Usporedba histograma korištenjem χ^2 (hi-kvadrat) udaljenosti

Metoda usporedbe histogramom korištenjem hi-kvadrat udaljenosti spada u *bin-to-bin* usporedbu slika. Histogram je grafička reprezentacija distribucije brojčanih podataka. On daje procjenu vjerojatnosti razdiobe kontinuiranih varijabli u obliku stupčastog grafa. Da bi se dobio histogram, prvi korak je smjestiti vrijednosti u određene „kante“, sekcije (eng. *bins*), odnosno podijeliti niz vrijednosti na određeni broj intervala.

Primjerice, ukoliko je slika crno-bijela, vrijednosti elemenata takve slike bit će u intervalu $[0,255]$, te se za svaki od elemenata intervala prebrojava koliko vrijednosti elemenata slike sadržava određenu vrijednost intervala.



Sl. 4.1. Primjer histograma slike u crno-bijeloj boji

Razlika između dvije slike računa se pomoću formule za hi-kvadrat udaljenost. Normalizacija putem hi-kvadrat udaljenosti i podjela slike na takozvane sekcije, smanjuje efekt pretjeranog utjecaja velikih područja. Iako, hi-kvadrat normalizacija je osjetljiva na kvantizacijski efekt, koji može biti prouzrokovao svjetlosnim promjenama i deformacijama oblika [18].

Formula korištena za računanje hi-kvadrat udaljenosti u algoritmu je sljedeća:

$$\sum_{i=1}^n \frac{(x_i - y_i)^2}{x_i + y_i} \quad (4-1)$$

pri čemu je prvi član, x_i , jednak i -tom elementu histograma matrice slike originalnog videozapisa, a drugi član, y_i , jednak i -tom elementu histograma matrice slike promatranog videozapisa. Sinkronizacija se vrši na način da se uzme prva slika videozapisa referentnog videozapisa, i prva

slike videozapisa promatranog videozapisa. Kako bi se povećala točnost algoritma, svaka slika je podijeljena na n različitih područja, i zapravo se uspoređuju ista područja jedne i druge slike. Broj područja se dobije množenjem visine i širine slike, te dijeljenjem s 25600, koji je eksperimentalno dobiven kao najveći zajednički višekratnik poznatijih rezolucija. Primjerice, za rezoluciju 1920x1080, broj područja koje se uspoređuje je:

$$x = \frac{\text{visina} * \text{širina}}{\text{NZV}(\text{rez})}$$

$$x = \frac{1920 * 1080}{25600} = 81 \quad (4-2)$$

Primjer rezultata algoritma za dvije slike originalnog i promatranog videozapisa koje nisu označene kao sinkronizirane, dane su u tablici 4.2.

Tab 4.2. Prikaz rezultata usporedbom histograma korištenjem hi-kvadrat udaljenosti za nesinkronizirajuće slike videozapisa

$(i/j)(10^{-2})$	1	2	3	4	5	6	7	8	9
1	4,933	6,627	7,1383	6,71	7,945	8,32	7,243	7,136	7,136
2	1,878	2,589	0,934	3,286	1,97	1,929	3,153	3,701	3,782
3	1,489	1,089	2,349	2,20	0,978	1,661	2,00	0,546	1,658
4	1,750	4,357	3,126	1,683	1,727	1,591	2,726	1,323	2,020
5	4,151	7,641	10,479	11,629	5,174	3,527	1,722	2,088	4,413
6	7,544	1,454	1,558	6,240	1,694	3,938	4,542	7,296	12,286
7	2,210	1,624	2,100	0,730	1,112	2,602	3,025	2,073	0,954
8	6,180	2,522	4,453	3,544	5,115	5,845	2,240	4,125	0,488
9	25,589	15,766	9,272	7,026	3,624	5,926	4,260	16,898	3,179


Raspon udaljenosti je u zatvorenom intervalu $[0,1]$. Najveća razlika u vrijednosti nalazi se na poziciji (9,1), čija je vrijednost $25,580 * 10^{-2}$, dok je najmanja vrijednost na poziciji (8,9) a iznosi $0,488 * 10^{-2}$. Obzirom na formulu, razlika vrijednosti osnovnih elemenata slike je dosta velika i jednostavno je za zaključiti da se ne radi o istim slikama. Dvije identične slike bi dale matricu čije bi sve vrijednosti bile jednake nuli, dok dvije potencijalno sinkronizirajuće slike bi trebale davati vrijednosti vrlo blizu nuli, reda veličine 10^{-4} do 10^{-6} . U tablici 4.3. dani su rezultati sinkronizirajuće točke promatranog videozapisa i prve slike odabranog referentnog videozapisa.

Tab 4.3. Prikaz rezultata usporedbom histograma korištenjem hi-kvadrat udaljenosti za sinkronizirajuće slike videozapisa

$(i/j)(10^{-2})$	1	2	3	4	5	6	7	8	9
1	1,928	2,056	1,215	1,172	1,472	1,130	0,870	0,988	2,053
2	0,845	0,246	0,764	0,680	0,366	0,371	0,362	0,392	0,784
3	0,453	1,198	1,647	0,894	1,316	1,221	1,638	2,147	0,985
4	1,008	0,619	1,131	2,746	1,598	3,244	5,496	4,200	9,760
5	4,970	1,634	0,320	0,716	1,452	1,284	0,704	0,580	1,163
6	2,302	0,946	5,813	1,179	1,134	1,116	0,429	1,779	2,026
7	0,535	1,509	4,248	0,463	4,494	1,382	1,244	0,070	2,012
8	2,276	1,722	5,6892	1,774	1,509	7,901	1,928	0,692	2,095
9	1,287	7,344	1,679	6,332	4,482	1,023	8,303	1,198	5,083

Razlika suma ovih matrica je naizgled velika, no radi se o redu veličine 10^{-2} do 10^{-3} . Ukoliko se promatra samo tablica 4.2. rezultati nisu obećavajući, jer je i dalje najveća vrijednost, 9,760 reda veličine 10^{-2} , što je dosta velika vrijednost za ovakvu metodu. Najmanja vrijednost, $0,362 \cdot 10^{-2}$ je svejedno vrlo visoka za područja slike koja bi trebala biti identična. Također, teško je odrediti granicu do koje se prihvaća razlika vrijednosti u slikama. Obzirom da se očekivane vrijednosti bitno razlikuju od dobivenih, izvršena je detaljnija usporedba jedne slike originalnog videozapisa i slike s uređaja za dohvaćanje slika sa toka.

Uočen je problem da uređaj za dohvaćanje slika unosi vlastiti šum, na nasumičnim mjestima, različite gustoće, oblika i boje osnovnih elemenata slike, koje su dovoljne da obezvrijede ovakvu metodu. Metoda je osjetljiva na kvantizacijski efekt, koji može biti prouzrokovan svjetlosnim promjenama i deformacijama oblika, a ovakav tip šuma uzrokuje sličnu ili istu situaciju.



5.3 Metoda apsolutne razlike osnovnih elemenata slike (eng. *pixel comparison*)

Ideja metode koja uspoređuje dvije slike na temelju osnovnih elemenata slike na istim mjestima u matrici je da se zanemari utjecaj nepravilnosti unešene *grabberom*. Metoda se temelji na računanju razlike između dva elementa slike. Primjerice, uzima se element (1,1) prve slike i element (1,1) druge slike, računa se prosječna vrijednost R, G i B komponenti slike, na način:

$$px_{average} = \frac{M[i,j]_R + M[i,j]_G + M[i,j]_B}{3} \quad (4-3)$$

pri čemu je $M[i,j]$ pozicija elementa slike unutar matrice slike, a indeksi R, G i B slijedom označavaju crvenu, zelenu i plavu komponentu. Za obje slike provodi se ista metoda, i oduzimaju se vrijednosti na istim pozicijama:

$$px_{diff} = |M[i,j]_1 - M[i,j]_2| \quad (4-4)$$

te se dobija apsolutna razlika između dvije točke na slici.

HD slika, rezolucije 1920x1080, sveukupno ima 2073600 elemenata slike. Eksperimentalnom metodom, postavljen je prag tolerancije za razliku u elementima slike na 600, zbog prethodno detektiranog unošenja nepravilnosti od strane uređaja za dohvaćanje slika. Dvije slike, čije su ukupna razlika u elementima slike manje od 600 smatraju se sinkronizirajućim.

Međutim, uočen je novi problem. Uređaj za dohvaćanje slika osim što mijenja rezoluciju slike (širinu i visinu), mijenja i vrijednost osnovnih elemenata slike, to jest boju slike, metodom **bilinearne interpolacije**. Iz tog razloga, postavljeni su dva dodatna uvjeta:

1. prag osjetljivosti na boje – osnovni elementi slike se mogu razlikovati u vrijednosti do 20 jedinica (što je prihvatljivo, budući da je interval vrijednosti [0,255], stoga je prag osjetljivosti ~8%)
2. uvjet n/m sinkronizirajućih slika – kako bi se sa sigurnošću moglo reći da je pronađena točka sinkronizacije dvaju videozapisa, n od ukupno m slika za redom se moraju poklapati (moraju biti sinkronizirane metodom apsolutne razlike elemenata slike). Eksperimentalno, n je postavljen na 5, m na 7.

U takav algoritam, ubačene su testne sekvence s promjenjivim konstantnim faktorom stope, te su zabilježeni rezultati prikazani u tablicama 4.4. i 4.5.

Tab 4.4. Rezultati metode apsolutne razlike elemenata slike za videozapis Beauty1080p

Beauty		Konstantni faktor stope (CRF)													
H264	18			25			30			35			40		
	Nasumično vrijeme/okvir														
	564	301	129	51	71	212	42	189	310	546	340	506	298	491	
	0	3	0	18	21	17	213	74	106	1025	638	1974	3740	10371	
	Nasumično vrijeme/okvir														
H265	529	347	87	436	147	300	529	223	379	54	175	318	441	109	
	8	0	3	68	10	9	364	81	283	843	321	601	2833	3583	
	Kvantizacijski parametar(QP)														
MPEG4	10			13			15			20			25		
	593	310	483	171	510	191	423	29	97	179	316	528	245	415	
	16	11	46	32	30	102	47	133	144	289	201	241	961	410	

Tab 4.5. Rezultati metode apsolutne razlike elemenata slike za videozapis Bosphorus1080p

Bosph		Konstantni faktor stope (CRF)													
H264	18			25			30			35			40		
	Nasumično vrijeme/okvir														
	223	25	152	351	29	84	199	206	333	512	7	34	293	598	
	47	79	59	686	883	489	1032	2158	1299	3383	2835	2217	12567	16255	
	Nasumično vrijeme/okvir														
H265	34	85	306	412	374	399	500	206	232	134	556	477	492	207	
	39	84	27	785	583	933	1174	1348	1417	4214	3723	5477	18233	14023	
	Kvantizacijski parametar(QP)														
MPEG4	10			13			15			20			25		
	333	241	89	93	109	198	390	122	208	309	398	112	25	506	
	107	233	92	944	760	1283	4032	2765	1977	5036	3420	7033	22443	31500	

U tablicama 4.4. i 4.5. prikazani su neki od rezultata testiranja metode apsolutne razlike osnovnih elemenata slike. Cilj je bio provjeriti do kojeg stupnja degradacije slike je moguće korištenje

ovakve metode, te na kakvih videozapisima je ovakva metoda pogodna, odnosno koja su njena ograničenja.

Za dva originalna videozapisa, Beauty1080p i Bosphorus1080p, stvoreni su degradirani videozapisi s konstantnim faktorom stope 18, 25, 30, 35 i 40, te kvantizacijskim parametrima 10, 13, 15, 20, 25. Videozapisi su kodirani pomoću tri tipa koda: H264, H265 i MPEG-4. Za svaki od videozapisa, nasumično (programski) su odabrane tri točke za sinkronizaciju (odnosno tri nasumična okvira u ukupnom broju okvira). Rezultati prikazuju broj elemenata slike koji se razlikuju u sinkronizacijskim točkama, te su prihvatljivi oni čija je razlika manja od 600 (obojani zeleno).

Algoritam pravi dobre rezultate na sporopromjenjivim videozapisima. Na videozapisima koji imaju veće pokrete, dolazi do većih ukupnih razlika u elementima slike. Problem nastaje, kada treba odrediti stupanj osjetljivosti algoritma, jer nije poznata kvaliteta promatranog videozapisa. Ukoliko su već za male konstantne faktore stope i kvantizacijske parametre, odstupanja veća od očekivanih, teško je odrediti radi li se o nekvalitetnom videozapisu ili nedovoljno dobrim postavkama algoritma. Zbog novouočenih problema, odnosno primjene bilinearne interpolacije na slike ulaznog videozapisa uređaja za dohvaćanje slika, ova metoda nije pogodna za sinkronizaciju dvaju videozapisa.

5.4 *Freezing* algoritam

Za provjeru sličnosti okvira korišten je i algoritam provjere smrzavanja slike (u pravilu bi slike trebale biti identične, ili uz minimalne razlike da bi algoritam prepoznao smrzavanje.) U teoriji bi ovakav algoritam trebao raditi, no spoznajom da *grabber* vrši degradaciju i reskaliranje slike, a radi se o BBT testiranju, prevelike se promjene unose u promatrani videozapis da bi ovakva metoda urodila plodom.

6 ZAKLJUČAK

U ovom radu, predstavljena je teorijska podloga radi lakšeg shvaćanja problematike i razloga usporedbe referentnog i prikazanog videozapisa pri testiranju DTV uređaja BBT metodologijom. Pojašnjeno je područje primjene unutar HbbTV standarda. Prikazana su postojeća rješenja koja pomažu pri usporedbi dvaju videozapisa (algoritmi usporedbe dvaju slika i QR kodova), objašnjen je način provođenja testiranja, realizirana su višestruka rješenja (usporedba matrica korištenjem hi-kvadrat udaljenosti, usporedba osnovnih elemenata slike, algoritam detekcije ispuštanja okvira), u potrazi za konačnim rješenjem (metoda sinkronizacije i procjene kvalitete korištenjem N PSNR lokalnih maksimuma). Opisano je vlastito rješenje, izvršena su mjerenja, te su prikazani i objašnjeni rezultati mjerenja za sve navedene algoritme.

Prvotno testirani algoritmi, većinom su davali loše rezultate pri usklađivanju videozapisa – nisu zadovoljavali kriterije i bilo je nemoguće pronaći optimalnu situaciju za sve sekvence.

Glavni zadatak bio je pronaći adekvatan način za sinkronizaciju dvaju videozapisa, sa i bez QR koda, te nakon vremenske usklađenosti, procijeniti kvalitetu rekonstruiranog videozapisa. Prema rezultatima mjerenja, algoritmi uspješno izvršavaju zadatke u svim provedenim testiranjima. Jedina ograničenja algoritama ovise direktno o algoritmima i bibliotekama koje koriste: biblioteka za čitanje QR kodova (kvalitativno i vremensko ograničenje) i algoritam računanja PSNR-a (vremensko ograničenje).

Algoritam je jedinstven, uspješno rješava zadanu problematiku, te se na temelju njegovih rješenja može vršiti daljnja analiza videozapisa ili stvoriti slika o kvaliteti DTV uređaja koji se testira. Algoritam je objektivan, automatizira proces usklađivanja i omogućuje detaljne informacije o kvaliteti rekonstruiranog videozapisa.

7 LITERATURA

- [1] “IEEE Standard Glossary of Software Engineering Terminology,” *IEEE Std 61012-1990*, pp. 1–84, Dec. 1990.
- [2] D. Jiménez Bermejo, “High definition video quality assessment metric built upon full reference ratios,” phd, E.T.S.I. Telecomunicación (UPM), 2012.
- [3] L. Zhang, L. Zhang, X. Mou, and D. Zhang, “FSIM: A Feature Similarity Index for Image Quality Assessment,” *IEEE Trans. Image Process.*, vol. 20, no. 8, pp. 2378–2386, Aug. 2011.
- [4] Z. Wang, L. Lu, and A. C. Bovik, “Video quality assessment based on structural distortion measurement,” *Signal Process. Image Commun.*, vol. 19, no. 2, pp. 121–132, Feb. 2004.
- [5] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, “Image quality assessment: from error visibility to structural similarity,” *IEEE Trans. Image Process.*, vol. 13, no. 4, pp. 600–612, Apr. 2004.
- [6] C. W. Ng, I. King, and M. R. Lyu, “Video Comparison Using Tree Matching Algorithm,” in *In Proceedings of The International Conference on Imaging Science, Systems, and Technology*, 2001, pp. 184–190.
- [7] E. Colucci, “Image and Video quality assessment – Part Two: SSIM Index,” Jun-2011. [Online]. Available: <http://emanuelecolucci.com/2011/06/image-and-video-quality-assessment-part-two-ssim-index/>. [Accessed: 31-May-2017].
- [8] I. Sedano, K. Brunnström, M. Kihl, and A. Aurelius, “Full-reference video quality metric assisted the development of no-reference bitstream video quality metrics for real-time network monitoring,” *EURASIP J. Image Video Process.*, vol. 2014, no. 1, p. 4, Dec. 2014.
- [9] S. Chikkerur, V. Sundaram, M. Reisslein, and L. J. Karam, “Objective Video Quality Assessment Methods: A Classification, Review, and Performance Comparison,” *IEEE Trans. Broadcast.*, vol. 57, no. 2, pp. 165–182, Jun. 2011.
- [10] A. S. Narayanan, “QR Codes and Security Solutions,” *Int. J. Comput. Sci. Telecommun.*, vol. 3, no. 7, pp. 69–72, Jul. 2012.
- [11] ETSI, *ETSI TS 102 796 V1.4.1 (2016-08)*. 2016.
- [12] M. Z. Bjelica, M. Teslić, and V. Mihić, *Softver u televiziji i obradi slike 1: Osnove digitalne televizije i video kodovanja*, V1.0. 2017.

- [13] W. K. Edwards, M. W. Newman, T. F. Smith, J. Sedivy, and S. Izadi, “An extensible set-top box platform for home media applications,” *IEEE Trans. Consum. Electron.*, vol. 51, no. 4, pp. 1175–1181, Nov. 2005.
- [14] B. Campbell, “Whitepaper on HbbTV Testing for Broadcasters and Operators.” Nov-2015.
- [15] D. Beer, *quirc: QR decoder library*. 2017.
- [16] *zxing-cpp: ZXing C++ Library*. Glass Echidna, 2017.
- [17] Tampere University of Technology, “Ultra Video Group High Quality Testing Video Sequences,” *UltraVideo HD Video Testing Sequences*, 2013. [Online]. Available: <http://ultravideo.cs.tut.fi/#testsequences>. [Accessed: 01-Jun-2017].
- [18] O. Pele and M. Werman, “The Quadratic-Chi Histogram Distance Family,” in *Computer Vision – ECCV 2010*, 2010, pp. 749–762.

8 SAŽETAK

Ovim radom, opisana je problematika usklađivanja i vrednovanja rekonstruiranog videozapisa u odnosu na referentni. Prikazan je pregled metoda i algoritama za procjenu kvalitete slika s referencom. Opisana je teorijska pozadina HbbTV tehnologije radi lakšeg shvaćanja zadatka. Objašnjena je nekolicina različitih metoda s ciljem rješavanja zadanog problema – usporedba matrica korištenjem hi-kvadrat udaljenosti, usporedba osnovnih elemenata slike, algoritam detekcije ispuštanja okvira, te su dani rezultati mjerenja i nedostaci algoritama. Predstavljen je vlastiti algoritam za sinkronizaciju i evaluaciju rekonstruiranog videozapisa s referencom, za dva slučaja: videozapisi s QR kodom, te videozapisi dohvaćeni s *grabber* uređaja računanjem N PSNR lokalnih maksimuma. Rezultati mjerenja objašnjeni su vizualno, deskriptivno i grafički. Algoritam, koji je jedinstven, pokazao je visoke performanse, uspješno izvršava zadani zadatak, te daje detaljne informacije o promatranom videozapisu.

Ključne riječi:

black-box testiranje, HbbTV, digitalni televizijski prijemnik, sinkronizacija, evaluacija

9 ABSTRACT

Video synchronization and full reference video quality assessment have been described in this paper. Methods and algorithms for image quality assessment are presented. HbbTV technology has been pictured in order to facilitate the understanding of the assignment. Several different methods with intention of resolving the given problem have been explained – matrix comparison computing the chi-squared distance; picture element (pixel) comparison; freezing algorithm. Testing results and disadvantages have been given respectively. A unique algorithm for synchronization and evaluation of reconstructed video with reference is proposed for the two cases: video sequences with QR code and video sequences pulled from grabber device using N PSNR local maximums. Measurement results are visually, descriptively and graphically presented. Unique algorithm shows high performance, successfully resolves the problem and gives detailed information about the observed video.

Keywords:

black-box testing, HbbTV, digital receiver, synchronization, evaluation

10 ŽIVOTOPIS

Josip Vojak je rođen 8.10.1993. godine u Slavonskom Brodu. Osnovnu školu završio je u osnovnoj školi „Hugo Badalić“ 2008. godine u Slavonskom Brodu. Prirodoslovno-matematičku gimnaziju pohađa i završava također u Slavonskom Brodu 2012. godine. Nakon toga upisuje sveučilišni preddiplomski studij, smjer računarstvo, na Elektrotehničkom fakultetu u Osijeku. 2015. godine završava preddiplomski i upisuje diplomski studij Fakulteta elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. Tokom cjelokupnog obrazovanja, prolazi sa odličnim uspjehom i natječe se na županijskim, regionalnim i državnim natjecanjima iz školskog znanja: matematika, informatika, engleski jezik, hrvatski jezik, te iz sporta: nogomet, odbojka, atletika. Od kolovoza 2015. do studenog 2017. bio je jedan od glavnih razvojnih inženjera i suosnivač start-upa GamingBattleGround. Honorarno je sudjelovao u nekolicini projekata u eSports domeni, te je aktivan freelancer. Od 2015. praktikant je tvrtke RT-RK. Na humanitarnoj akciji Good Game Global, u svibnju 2016. bio je odgovoran za tehničku podršku (softver i hardver). Kao demonstrator, pomagao je na fakultetu u području dizajna i arhitekture računalnih sustava. Član je verifikacijskog odbora sportskog odjela Fakulteta elektrotehnike, računarstva i informacijskih tehnologija, član je IEEE instituta. Trenira odbojku od 2004., te je svojevremeni član juniorske i seniorske muške odbojkaške reprezentacije Hrvatske, s kojima je sudjelovao na kvalifikacijama za europska i svjetska prvenstva na Cipru, Ukrajini, Srbiji i Sloveniji. Nastupao je za prvoligaške klubove „Mok Brod“ i „Mok Mursa-Osijek“, s kojima bilježi drugo i treće mjesto prvenstva Hrvatske, sudjelovanje u Confédération Européenne de Volleyball (CEV) kupu i CEV Volleyball Challenge Cupu, nakon čega mu je dodijeljena III. razina kategorizacije sportaša. 2013. godine, dodijeljena mu je stipendija za uspješnost u studiranju grada Slavanskog Broda. Aktivno govori, čita i piše hrvatskim i engleskim jezikom, dok na osnovnoj razini razumije i njemački jezik.